



ZÜRCHER HOCHSCHULE FÜR ANGEWANDTE WISSENSCHAFTEN
DEPARTEMENT LIFE SCIENCES UND FACILITY MANAGEMENT
INSITUT IUNR

Einsatz von Drohnen zur Beurteilung von Lebensräumen auf der Alp Muotselvas

Bachelorarbeit

von

Monja Salvisberg

Bachelorstudiengang 2016

Abgabedatum: 24.10.2019

Studienrichtung Umweltingenieurwesen

Fachkorrektoren:

Dr. Edelkraut, Kirsten

ZHAW, Schloss, 8820 Wädenswil

Dr. Junghardt, Johann

ZHAW, Grüental, 8820 Wädenswil

Impressum

Schlagworte

Biodiversitätsförderflächen, Drohnen, RGB, multispektral, Structre from motion (SfM), Objekt-basierte Bildklassifikation (OBIA), Support Vector Machine (SVM), Höhenmodell, NDVI, ExG

Zitiervorschlag

Salvisberg, M. (2019). *Der Einsatz von Drohnen zur Beurteilung von Lebensräumen auf der Alp Muotse/vas*. Bachelorarbeit, ZHAW Wädenswil, Departement N, Institut IUNR, Fachstelle Umweltplanung.

Institut:

Zürcher Hochschule für Angewandte Wissenschaften ZHAW

Life Sciences and Facility Management

Grüental, Postfach

CH-8820 Wädenswil

Autorin:

Monja Salvisberg

Gwattstrasse 65

CH-3645 Gwatt (Thun)

Zusammenfassung

Zum Erhalt und Förderung der Biodiversität und des Schweizer Naturkapitals werden Biodiversitätsförderflächen (BFF) in Sömmerungsgebieten inventarisiert und regelmässig kontrolliert. Diese Arbeit versucht am Beispiel der Alp Muotselvas zu prüfen, ob mit dem Einsatz von Drohnen Lebensräume abgegrenzt werden können. Zudem stellt sich die Frage, ob jeder dieser Lebensräume ein spezifisches Farbspektrum aufweist. Das Untersuchungsgebiet befindet sich im Val Fex im schweizerischen Oberengadin, beträgt ungefähr 46ha und liegt ca. zwischen 2100 und 2400 m.ü.M.. Ein RGB (rot, grün, blau) sowie ein multispektraler (Nahinfrarot) Sensor wurden auf eine Sensefly eBee plus Drohne montiert. Anhand der Methode 'Structure from Motion' aus der Luftbildphotogrammetrie wurden in Pix4D Orthomosaik, Höhenmodelle und Reflektionskarten erstellt. Eine überwachte, Objekt-basierte Bildklassifizierung mit dem Algorithmus 'Support Vector Machine' generiert in ArcGIS Pro eine thematische Lebensraumkarte. Der RGB Datensatz eignete sich wegen besserer Bildauflösung für die Erstellung einer Lebensraumkarte sowie die Ermittlung der produktiven Weideflächen mit Futterwert besser als der multispektrale. Die Extraktion des Höhenmodells und der Vegetationsindizes (NDVI, ExG) haben die Ergebnisse allgemein wesentlich verbessert. Ein spezifisches Spektralprofil der Lebensräume konnte mit dieser Methode nicht ermittelt werden. Während der Einsatz von Drohnen bei der Erfassung und Kontrolle der BFF hilfreich ist, blieb eine initiale, ausführliche terrestrische Begehung dennoch notwendig. Multispektrale und hyperspektrale Sensoren sind ein vielversprechendes Mittel zur Untersuchung von Lebensräumen und die Verbreitung von Arten. Ihr Drohnen-gestützter Einsatz sollte weiterhin erforscht werden.

Abstract

In order to conserve and promote biodiversity and the swiss natural capital in summering alps, areas with special biological quality are inventoried and regularly inspected. Using the example of the Alp Muotselfas, this work attempts to examine whether drones can be used to delimitate habitats. In addition, the question arises whether these habitats have a specific color spectrum. The study area is located in the Fex valley in the Swiss Upper Engadin between 2100 and 2400 m above sea level. An RGB and a multispectral Sensor were mounted on a Sensefly eBee plus drone. Using the 'Structure from Motion' method from aerial photogrammetry, orthomosaics, elevation models and reflection maps were created in Pix4D. A supervised, object-based image classification using the "Support Vector Machine algorithm" was executed in ArcGIS Pro. The RGB dataset was due to better Sensors more suitable for the creation of a habitat map and the determination of the productive pastureland with fodder value than the multispectral data. Overall, the results were significantly improved by adding the extraction of the elevation model and the vegetation indices (NDVI, ExG). A specific spectral profile of the habitats could not be determined with this method. While the use of drones to record and control the areas with special biological quality is helpful, an initial, detailed field survey remains necessary. Multispectral and hyperspectral sensors are promising tools for studying habitats and the distribution of species. Further drone-based studies are needed.

Inhaltsverzeichnis

1	Einleitung	6
2	Material und Methoden	9
2.1	Datenerfassung.....	11
2.1.1	Drohnenflug	11
2.1.2	Terrestrische Begehung	13
2.2	Datenvorbereitung.....	17
2.2.1	Pix4D	17
2.2.2	ArcGIS Pro.....	18
2.3	Datenverarbeitung.....	20
2.3.1	Segmentation.....	20
2.3.2	Trainingsgebiet-Manager	21
2.3.3	Klassifikation	21
2.3.4	Genauigkeitsanalyse	23
2.3.5	(i) Einteilung in Lebensräume.....	23
2.3.6	(ii) Ermittlung der produktiven Weidefläche	24
2.3.7	(iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes	24
3	Resultate.....	25
3.1	(i) Einteilung in Lebensräume.....	25
3.2	(ii) Ermittlung der produktiven Weidefläche	32
3.3	(iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes	34
4	Diskussion	35
4.1	(i) Einteilung in Lebensräume.....	36
4.2	(ii) Ermittlung der produktiven Weidefläche	39
4.3	(iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes	41
4.4	Kontext zur Nachhaltigkeit.....	42
4.5	Fazit	43
5	Literaturverzeichnis.....	44
6	Abbildungsverzeichnis	47
7	Tabellenverzeichnis	49
	Anhang.....	50

1 Einleitung

Sommerungsgebiete sind nicht nur ein Kennzeichen der vielfältigen Schweizer Kulturlandschaft, sie gehören auch zu den artenreichsten Lebensräumen der subalpinen und alpinen Höhenstufen. Durch Rodungen und saisonale Wanderung konnten sich Tier- und Pflanzenarten aus verschiedensten Gebieten etablieren. Das Mikroklima ist durch Standortfaktoren wie Höhe, Hangneigung und Exposition auf kleinstem Raum sehr unterschiedlich und bietet gerade deshalb grosses Potential für Artenvielfalt. In den Nischen mit gleichen Umweltbedingungen stellen sich typische Artkombinationen ein (Lauber Herzog, Seidl, Böni, Bürgi, Gmür, Hofer, Mann, Raaflaub, Schick, Schneider & Wunderli, 2013). Alpine Rasen, Zwergstrauchgesellschaften, Grünerlengebüsche und Arven-/ Lärchenwälder sind auf der Höhenstufe vorherrschend (Delarze, Gonseth, Eggenberg & Vust, 2015; Lauber, Wagner, Gygax, Eggenberg, Bornand, Juillerat, Jutzi, Möhl, Nyffeler & Santiago, 2018).

Rund 17'000 Älpler und Älplerinnen sorgen jährlich mit beinahe 800'000 Tieren für die Offenhaltung artenreicher Flächen und schützen die Täler vor Naturgefahren (Lauber, Schüpbach & Koch, 2017). Wird eine Alp aufgegeben, kommt es schnell zur Verbuschung durch Zwergsträucher, Grünerlen und Bäumen, wird sie zu intensiv genutzt, verarmen Flora und Fauna (Delarze et al., 2015; Lauber et al., 2013). Übernutzung fördert zudem Problempflanzen wie die Alpen-Blake oder das Alpen-Kreuzkraut, welche vom Vieh verschmäht werden und somit den Futterwert der Weidefläche herabsetzen (Jucker & Werder, 2015).

Für den Erhalt und die Förderung von Arten und ihren Lebensräumen legt der Bund im Bundesgesetz über die Landwirtschaft Art. 73 („Bundesverfassung der Schweizerischen Eidgenossenschaft (BV)“, 2000) fest, dass artenreiche Grün- und Streuflächen im Sommerungsgebiet, welche die Qualitätsstufe II erreichen, mit einem Beitrag pro Hektare subventioniert werden ("Verordnung über die Direktzahlungen an die Landwirtschaft (DZV)", 2013).

Nach Anmeldung dieser Biodiversitätsförderflächen (BFF) ist während einer Verpflichtungsdauer von 8 Jahren der Erhalt in Grösse und Qualität sowie entsprechender Bewirtschaftung eine Bedingung. Zudem müssen Indikatorpflanzen, welche auf einen nährstoffarmen und artenreichen Bestand hinweisen, regelmässig vorkommen (Benz, 2014a; Bundesamt für Landwirtschaft, 2018).

Die Ersterfassung sowie die Kontrolle der BFF wird von Umweltfachleuten in Form von Vegetationsaufnahmen während terrestrischen Begehungen durchgeführt. Gemäss Benz (2014b) werden BFF-Teilflächen aufgrund von Bewirtschaftungseinheiten und gleichmässigem Anteil und Verteilung der Lebensraumtypen und Indikatorpflanzen abgegrenzt. Weil Qualitätsvegetation und Vegetation ohne Qualität oft ein Mosaik bilden, ist es für Fachleute eine grosse Herausforderung klare und nachvollziehbare Grenzen zu ziehen. Weiter wird pro BFF-

Qualitätsflächen der Anteil mit unproduktiven Elementen und / oder Vegetation ohne Indikatorpflanzen geschätzt. Jene mit über 10% unproduktivem Flächenanteil erhalten einen Beitragsabzug, der durch den Kanton berechnet wird (Benz, 2014b). Obwohl alle nach der gleichen Methode erfasst werden, bleiben Schätzungen subjektiv. Mit zunehmender Alpgrösse und Schwierigkeit des Geländes steigen indes auch der Zeitaufwand und die Kosten.

Um solche Konflikte der täglichen Planungspraxis zu lösen, kommen in der Umweltbranche seit einiger Zeit Methoden der Fernerkundung zum Einsatz. Mit ihnen können grössere Gebiete über längere Zeiträume untersucht werden (Durfee, Ochoa & Mata-Gonzalez, 2019). Die gewonnen Datenpakete werden anschliessend mit geographischen Informationssystemen (GIS) quantitativ und qualitativ analysiert.

Zu den bedeutendsten technologischen Innovationen der letzten zehn Jahre gehören Drohnen (Christen, Guillaume, Jablonowski, Lenhart & Moll, 2018), auch unbemanntes Fluggerät (UAV – unmanned aerial vehicle) oder unbemanntes Flugsystem (UAS - unmanned aerial system) genannt (Baumgärtel & Landrock, 2018). Sie fliegen tiefer als Flugzeuge oder Satelliten und erfassen deshalb hoch aufgelöste Bilddaten mit Pixelgrössen im Zentimeterbereich (Hunt Jr. & Daughtry, 2018; Torres-Sánchez, Peña, de Castro & López-Granados, 2014). Zudem können Drohnen auch bei leicht bewölkter Wetterlage fliegen, sind einfacher zu konfigurieren und nicht auf einen Piloten angewiesen. Die Befliegung kann so, flexibler geplant werden (Torres-Sánchez et al., 2014).

Drohnen werden für Vegetationsanalysen mit RGB (rot, grün, blau) und Multispektralkameras ausgerüstet. RGB Sensoren liefern Bilder aus dem sichtbaren Lichtspektrum, multispektrale nehmen Licht aus dem nah-Infrarot (nir) Bereich auf (Baumgärtel & Landrock, 2018; Komárek, Klouček & Prošek, 2018; Laliberte, Goforth, Steele & Rango, 2011). Da Pflanzen verstärkt Licht im nah-Infrarot Bereich reflektieren, kann mit Hilfe von Vegetationsindizes wie dem NDVI (normalisierter, differenzierter Vegetationsindex) oder dem Excess Green einfacher zwischen vegetationsbedeckten und vegetationslosen Bereichen unterschieden werden (Durfee et al., 2019; Viljanen et al., 2018).

Durch Luftbildphotogrammetrie werden aus Luftbildern Höhenmodelle und Orthomosaike erstellt, welche später im GIS klassifiziert werden und der Erstellung von beispielsweise topographischen Karten dienen (Green, Congalton & Tukman, 2017). Im Umweltbereich finden diese Methoden Anwendung in der Präzisionslandwirtschaft (Baumgärtel & Landrock, 2018; Hunt Jr. & Daughtry, 2018), zur Analyse von Landschaftsstrukturveränderungen oder Vegetationskartierungen (Durfee et al., 2019; Komárek et al., 2018) sowie zur Überwachung von gefährdeten oder invasiven Arten (Babbi, Widmer, Ochsner & Krüsi, 2017).

In der Vergangenheit erfolgte die Bildklassifizierung oft mit pixelbasierten Verfahren. Dank der Entwicklung von neuen sehr hochauflösenden Sensoren liefern Objekt-basierte Verfahren

(OBIA, Object-based Image Analysis) bessere Resultate (Blaschke, 2009; Komárek et al., 2018; Laliberte et al., 2011).

OBIA stützt sich auf zwei methodischen Säulen; Segmentation und Klassifikation. Zuerst werden benachbarte Pixel, die Ähnlichkeiten (spektral, räumlich, kontext- und texturbasierend) aufweisen, zu Pixelgruppen zusammengefügt. Anschliessend werden die Gruppen anhand spektraler Eigenschaften klassifiziert (Green et al., 2017; Li, Zang, Zhang, Li & Wu, 2014).

Im Umweltprüfbericht 2017 bemängelte die OECD den Umstand, dass die Schweiz keine Übersicht hat, welche eine räumliche Verteilung der Habitate zeigt (OECD Umweltprüfbericht Schweiz 2017 (Kurzfassung), 2017). So liegt die Vermutung nahe, dass diese Technologien zur Abgrenzung von Lebensräumen im Sömmerungsgebiet eingesetzt werden können. Ein Erfolg würde sowohl den Umweltfachleuten zu Gute kommen als auch dem Ziel eine gesamtschweizerische Lebensraumkarte zu erarbeiten.

Forschungsfragen:

Im Rahmen dieser Arbeit wird ein Teilgebiet der Alp Fex im Oberengadin mit einer Drohne überflogen. Die Luftbilder werden anschliessend zu Orthomosaiken und Geländemodellen verarbeitet und in einem Geoinformationssystem ausgewertet. Mit den gewonnenen Daten soll geprüft werden, ob die Anwendbarkeit der Methode für die Kartierung und Überwachung von Biodiversitätsförderflächen hilfreich ist:

- (i) Wie weit lassen sich die erhobenen Luftbilddaten mit der angewandten Bildklassifizierung in Lebensräume einteilen?
- (ii) Wie viel Fläche des Untersuchungsgebiet ist produktives Weideland, d.h. Weideland mit einem Futterwert gemäss (Dietl, Berger & Ofner, 1981)?
- (iii) Welche Lebensräume des Untersuchungsgebiets können anhand eines spezifischen Farbspektrums zuverlässig identifiziert werden?

2 Material und Methoden

Das Untersuchungsgebiet 'Alp Muotselvas' befindet sich im Val Fex, einem Tal im Oberengadin in den Schweizer Zentralalpen (E = 2'778'938.0 / N= 1'140'593.0). Es handelt sich um einen Ausschnitt von ungefähr 46.5 ha des Sömmierungsgebiets der Alp Muotselvas (Abb. 1). Die Fläche liegt an einem Westhang beginnt oberhalb der Alphütte da Segl auf ungefähr 2100 m.ü.M. und endet auf einer Höhe von 2400 m.ü.M..

Oberhalb von 2000 m.ü.M. sind die klimatischen Verhältnisse fast überall gleich. Es herrscht Gebirgsklima, welches trotz hoher Niederschlagsmengen, durch die tiefen Mitteltemperaturen und häufigen Fröste, eine tiefe Luftfeuchtigkeit aufweist (Baltisberger, Nyffeler & Widmer, 2013). Im Untersuchungsgebiet gibt es nährstoffreiche und magere Weiden sowie verschiedenen Zwergstrauchgesellschaften, Krummholzgebüsche und Nadelhölzer wie Lärchen und Arven (Benz, 2014a; Dietl et al., 1981).




Abb. 1: Das Untersuchungsgebiet 'Alp Muotselvas' im Schweizer Oberengadin. In Rot sind die BFF Grenzen dargestellt. Gelb stellt den Weidezaun dar. Beide stammen aus den BFF-Erhebungsdaten 2017 von K. Edelkraut (ZHAW).

Der Arbeitsablauf gliedert sich in Datenerfassung, Datenvorbereitung und Datenverarbeitung. Die Abbildung 2 zeigt einen Gesamtüberblick der einzelnen Arbeitsschritte und den verwendeten Computerprogrammen.




Abb. 2: Schematische Übersicht über den Arbeitsablauf (schwarz). In grün sind die groben Prozessschritte dargestellt und in blau die dafür verwendeten Computerprogramme. Zur Darstellung der Ergebnisse 'produktives Weideland' wird zusätzlich Microsoft Excel verwendet.

2.1 Datenerfassung

2.1.1 Drohnenflug

Die Luftbilder wurden mit der Drohne eBee plus von Sensefly (Abb. 3) am 08.07.2019 zwischen 10:00 und 12:00 Uhr aufgenommen. Die Drohne hat mit den abnehmbaren Flügeln eine Spannweite von 110cm und wiegt etwa 1.1kg (je nach verwendeter Kamera). Folgende Kamertypen wurden verwendet:

Tab. 1: Eigenschaften der verwendeten senseFly Kamertypen S.O.D.A. und Parrot Sequoia +.

	senseFly S.O.D.A. 10.6 (RGB)	Parrot Sequoia+ 4.0 (nir)
Sensoren	Rot Grün Blau	rot (660nm ± 40nm) grün (550nm ± 40nm) rededge (735nm ± 10nm) nir (790nm ± 40nm)
Kamera Auflösung	20 Megapixel	1.2 Megapixel
Georeferenzierung Bilder	PPK (post processing kinematics)	Geotagging mittels drohneneigenem GPS
Weissabgleich	Automatisch, sonnig, wolkig, schattig	Automatisch
Bildformate	JPEG, DNG+JPEG	JPEG, TIF

Der multispektrale Sensor der Parrot Sequoia+ nimmt grün, rot, red-edge und nir auf. Ihr Sonnenscheinsensor erlaubt absolute Reflexionsmessungen ohne radiometrische Kalibration, der akut wechselnde Strahlungsintensität automatisch ausgleicht. Die RGB Daten der Parrot Sequoia+ werden aufgrund der tieferen Auflösung nicht verwendet. Das drohneneigene GPS/GNSS System nimmt für jede Aufnahme Positionsdaten auf, welche nach dem Flug mit den Bildern georeferenziert werden. In der S.O.D.A.-Kamera ist zudem ein PPK (post processing kinematics) Modul integriert, welches zusätzlich die genauen Lageinformationen der Drohne erfasst, um anschliessend die RGB Bilder mit den Satelliten-Korrekturdaten von swipos (Schweizer Positionierungsdienst des Bundesamts für Landestopografie) bis auf eine Positionsgenauigkeit von 3 cm zu korrigieren („senseFly eBee plus. Herstellerbroschüre.“, 2018). Die nächstgelegene GNSS-Referenzstation von swipos liegt in Samedan. Mit dieser Methode bedarf es nicht eines ständigen Funkkontakts der Bodenstation mit der Drohne und Passpunkte (GCP, Ground Control Point) müssen nicht mehr vorgängig im Feld positioniert werden. Die PPK-Methode ist nicht nur genauer, sie ist auch in unzugänglichen oder risikoreichen Gebieten anwendbar, in welchen eine Anbringung von Passpunkten nicht möglich wäre (Tomaščík, Mokroš, Surový, Grznárová & Merganič, 2019). Detaillierte Drohnen- und Kamera-Eigenschaften sind in Broschüren („senseFly eBee plus. Herstellerbroschüre.“, 2018; senseFly Parrot Group, 2019) oder auf den Herstellerseiten verfügbar.

Die Flugplanung wurde in eMotion 3 (eMotion, 2019) geplant. Der Flug erfolgte hangparallel von oben nach unten, was Batterie spart und die potenzielle Flugdauer erhöht (Abb. 3). Da nur eine Kamera an der Drohne eBee plus montiert werden kann, wurden zuerst die Echtfarbenerbilder mit der S.O.D.A. und in einem zweiten Flug, die multispektralen Bilder mit der Sequoia-Kamera aufgenommen.



Abb. 3: Die Drohne senseFly eBee plus und ihre Flugroute mit der Parrot Sequoia +. Geflogen wurde hangparallel von oben nach unten.

Die Flughöhe und -zeit ergaben sich im Allgemeinen nicht nur aus der gewünschten Auflösung, sondern auch aus der Grösse des Untersuchungsgebiets. Bei tieferer Flughöhe ist die Auflösung besser, aber die Datenmengen werden grösser und die Verarbeitung dauert länger. Damit es bei der Konstruktion des Orthomosaiks keine Lücken gibt, wurde eine ausreichend grosse Überlappung gewählt (Tab. 1). Die Wetterkondition waren passend: sonnig und tiefe Windgeschwindigkeiten. Während des zweiten Flugs zogen vereinzelt grössere und dichtere Wolken vorbei und der Wind wurde leicht stärker. Beide Flüge konnten problemlos durchgeführt werden. Die erfassten Flugdaten sind der Tab. 2 zu entnehmen.

Tab. 2: Zusammenfassung der wichtigsten Flugparameter der beiden Befliegungen am 07.08.2019 über Alp Muot-selvas, Val Fex, Oberengadin, Schweiz.

	senseFly S.O.D.A. 10.6(RGB)	Parrot Sequoia+ 4.0 (NIRGB)
Beflogene Fläche (ha)	97.6 ha	97.6 ha
Flughöhe (m)	119m / AED	116.7m /AED
Flugzeit (min)	25 min	28 min
Distanz zwischen Bildern (m)	41m	21m
Gesamtzahl Luftbilder	275	1884
Auflösung (cm/Pixel)	4.24 cm GSD	16.75 cm GSD
Laterale Überlappung (%)	70%	75%
Longitudinale Überlappung (%)	60%	80%
Anzahl kalibrierter Bilder	272 (98%)	1884 (100%)
Durchschnittliche Dichte der Punktwolken pro m³	36.28	0.25

2.1.2 Terrestrische Begehung

Aus der Literatur wurde während der Planung eine Auswahl an mutmasslich vorkommenden Lebensräumen zusammengestellt (Baltisberger et al., 2013; Delarze et al., 2015; Dietl et al., 1981; Lauber et al., 2018). Ein Schnelldurchlauf in Pix4D (*Pix4Dmapper*, 2019) generierte aus den RGB Luftbildern ein Orthomosaik. Beide Grundlagen begleiteten die Felduntersuchung, welche am 09.07.2019, zwei Tage nach der Befliegung, stattfand.

Die Map Marker-App (theandroidseb, 2019) ermöglichte es, an farblich, strukturell oder botanisch auffälligen Stellen auf der Karte Referenzpunkte zu setzen. Pro Punkt wurden dominante Arten der vorliegenden Vegetationsgesellschaft auf Gattungs- bzw. Art Niveau bestimmt. Grössere farbliche Veränderungen wie beispielsweise die Anhäufung vieler weisser Flechten liessen sich ebenfalls vermerken. Zwei bis drei Fotos pro Referenzpunkt ermöglichten, den Standort nachträglich nochmals in der App anzuschauen. Insgesamt konnten 36 Referenzpunkte gesammelt werden (Abb. 4). Zur Unterscheidung der Weidetypen wurde an drei Standorten mit optisch unterscheidbarer Pflanzenzusammensetzung Vegetationsaufnahmen aufgenommen und nach Dietl et al. (1981) ausgewertet (Anhang E). Zusätzlich diente eine Lebensraumannahme auf lebensraeume.unr.ch als Kurzcheck. Die drei Punkte werden später mit den Klassifizierungsergebnissen verglichen.




Abb. 4: Orthomosaik der Alp Muotselvas mit den auf das Untersuchungsgebiet angepassten BFF-Grenzen (rot), dem Weidezaun (orange) sowie den aus der terrestrischen Begehung (09.07.2019) erfassten Referenzpunkten (blau) und Vegetationsaufnahmen (Sterne gelb).

Die so gewonnenen Daten werden in ein Schema überführt, das es erlaubt die Bilder genauer zu klassifizieren (Abb. 5). Es wird grundsätzlich zwischen vegetationsreich und vegetationslos unterschieden. Zu vegetationslosen Bereichen zählen Steine, Boden und Wasser. Die Vegetation wurde in produktiv und unproduktiv eingeteilt. Alle verholzten Pflanzen wie Zwergsträucher, Krummholzgebüsche und Bäume zählten zu den unproduktiven Elementen und die Weideflächen mit einem Futterwert zu den produktiven Bereichen. Diese umfassten die alpinen Rasen, bestehend aus Borstgrasrasen (*Nardion*) und Krummseggenrasen (*Caricion curvulae*), der Bergfettweide (*Poion alpinae*) und den Lägerstellen (*Rumicion alpinae*). Lägerstellen haben nach der Direktzahlungsverordnung (DZV) keine BFF-Qualität (Hedinger, 2014), Bergfettweiden nur wenn die 6 Indikatorpflanzen vorkommen. Beide weisen gemäss Dietl et al. (1981) einen geringen Futterwert auf und werden in dieser Arbeit deshalb zu den produktiven Flächen gezählt.




Abb. 5: Schematische Unterteilung der einzelnen Klassen.

In Mulden und an feuchten Stellen sammelten sich nährstoffliebende Stauden wie Alpen-Ampfer (*Rumex alpinus*), Hahnenfuss (*Ranunculus* sp.), Frauenmantel (*Alchemilla* sp.), Rasenschmiele (*Deschampsia cespitosa*), Gewöhnliches Alpen-Lieschgras (*Phleum alpinum*), Läger-Rispengras (*Poa supina*), Alpen-Rispengras (*Poa alpina*), Getüpfelter Enzian (*Gentiana punctata*), Alpen-Kratzdistel (*Cirsium spinosissimum*) und einzelne anderen Arten. Sofern diese in dichten Flecken vorkamen, zählten sie zu den Lägerstellen, sonst zu nährstoffreichen Bereichen.



Abb. 6: Beispiel einer nährstoffreichen Mulden-Vegetation, Alp Muotselfas.

Eine Unterscheidung zwischen Borstgrasrasen oder Krummseggenrasen konnte auf dem Schnell-Orthomosaik nicht erkannt werden, sie wurden deshalb zu den alpinen Magerrasen zusammengefasst. Alpine Windheiden enthalten zwei verholzte, niederliegende, teppichbildende Spaliersträucher als Charakterarten: die Krähenbeere (*Empetrum nigrum* sp.) und die Gämsheide (*Loiseleuria procumbens*) (Delarze et al., 2015). Sie wurden zu den Zwergsträuchern gezählt. Die Alpenrosen (*Rhododendron ferrugineum*) waren zum Untersuchungszeitpunkt in roter Blüte, was auf dem schnell generierten Orthomosaik deutlich zu erkennen war. Sie stellen daher eine eigenständige Klasse innerhalb der Zwergsträucher dar.

2.2 Datenvorbereitung

2.2.1 Pix4D

Die photogrammetrische Bildverarbeitung der multispektralen Daten erfolgte mit der Software Pix4Dmapper 4.4.12 (Pix4Dmapper, 2019) in der ZHAW in Wädenswil. Die RGB Bilddaten wurden mit der Testversion Pix4Discovery am eigenen Laptop verarbeitet. Pix4D verwendet eine modifizierte SfM-MVS (Structure from Motion – Multi Stereo View) Methode, um die Bilddaten zu verarbeiten. SfM nutzt Algorithmen, die übereinstimmende Punkte aus sich überlappenden 2D Bildern identifiziert, Kamerapositionen und -orientierung berechnet und daraus 3D Punktwolken generiert. Mit MVS Algorithmen werden die Punktwolken verdichtet und wie in Abb. 7 ersichtlich eine 3D Rekonstruktion des Geländes erstellt (Carrivick, Smith & Quincey, 2016).

In dieser Arbeit wurde aus den RGB Daten ein Orthomosaik (GSD = 4.24 cm/Pixel), ein Digitales Oberflächen Modell (DOM; GSD = 4.24 cm/Pixel) und ein Digitales Terrain Modell (DTM; GSD = 5* 4.24 cm/Pixel) generiert. Aus den multispektralen Bilddaten wurden pro Band (Lichtkanal) vier Teilstücke erstellt. SfM-MVS Daten mit hoher Auflösung ergeben sehr grosse Datensets, welche die Verarbeitungszeit deutlich verlängern. Trotzdem ist die Datenverarbeitung gemäss Carrivick, Smith, & Quincey (2016) meist kürzer, als wenn alternative Vermessungsmethoden wie beispielsweise Terrestrial Laser Scanning verwendet werden. Weiterführende Angaben zu den Verarbeitungsschritten und den generierten Produkten aus Pix4D sind den Qualitätsreports (Anhang D) zu entnehmen (Abb. 2).




Abb. 7: 3D-Rekonstruktion des Untersuchungsgebiets Alp Muotselfvas. Rechts zeigt die Ansicht aus Südosten und links aus Nordosten.

2.2.2 ArcGIS Pro

Aus den Mosaikstücken der multispektralen Daten wurde in ArcGIS Pro (Esri Inc., 2019a) für jedes Band eine zusammenhängende Reflektionskarte erstellt. Zur Differenzierung der vegetationsreichen und vegetationslosen Bereiche wird der Vegetationsindex NDVI verwendet. Pflanzen reflektieren im Infrarot-Bereich viel mehr Strahlung als im sichtbaren Spektralbereich. Der NDVI nutzt die unterschiedlichen Reflektionsgrade des roten und infraroten Bandes, um die photosynthetische Aktivität von Pflanzen anzuzeigen (Durfee et al., 2019). Sein Wertebereich reicht von -1 bis 1, wobei positive Werte für vegetationsreiche und negative für vegetationslose Bereiche (Zhang, Wu, Yan & Chen, 2016) stehen.

$$NDVI = \frac{nir - red}{nir + red} \quad W_f = \mathbb{R} \setminus \{-1; 1\}$$

Aufgrund einer Überklassifizierung von vegetationslosen Flächen wurde der Schwellenwert auf 0.2 angehoben. Es folgte eine Reklassifikation des NDVI Layer in Wertebereiche, vegetationslos (< 0.2) und vegetationsreich (> 0.2) (Abb. 8). Schliesslich wurden die fünf Layer (rot, grün, infrarot, rededge und NDVI) zu einem Paket übereinandergelegt. Sie bildeten das Eingangsprodukt für die überwachte Bildklassifizierung der multispektralen Daten (Abb. 2).

Das Canopy Height Model (CHM), welches die effektive Vegetationshöhe darstellt, berechnete sich durch den Abzug des DTM vom DOM (Green et al., 2017). Für die Berechnung wurden die Pix4D Layer verwendet, da diese aufgrund des gleichen Ursprungs sicher deckungsgleich sind. Eine Reklassifikation des CHM Layers isolierte die Vegetationsschichten. Aufgrund der pflanzensoziologischen Stratifikation erfolgte eine Ersteinteilung, welche anschliessend aufgrund von Durchschnittshöhen häufig vorkommender Pflanzen, der Berücksichtigung des Wachstumsfortschritts sowie der Plausibilität der erzielten Ergebnisse angepasst wurde (Tab. 3). Die Isolation dient der Entnahme von Pflanzenschichten, was die Klassifikationsergebnisse erhöht (Viljanen et al., 2018).

Tab. 3: Die Vegetation wurde aufgrund pflanzensoziologischer Stratifikation und ihrer durchschnittlichen Höhe zur gegebenen Wachstumsphase in verschiedene Schichten isoliert. Die Resultate wurden mit dem RGB Orthomosaik verglichen und auf Richtigkeit überprüft.

Vegetationsschicht	Feinteilung	Wertebereich
Krautschicht	Gräser	0 – 0.25 m
	Zwergsträucher	0.25 – 0.8 m
	Hochstauden, Jungsträucher	0.8 – 1.5 m
Strauchschicht	Sträucher	1.5 – 3.5 m
Baumschicht	Bäume	3.5 – 15 m

Aus dem roten, grünen und blauen Band des Orthomosaiks wird der RGB basierte Vegetationsindex Excess Greenness (ExG) berechnet (Woebbecke, Meyer, Von Bargaen & Mortensen, 1995). Er ist sozusagen das Pendant zum NDVI, verwendet aber nur Bänder des sichtbaren Spektralbereichs.

$$ExG = (2 * g) - r - b \quad W_f = \mathbb{R} \setminus \{-2; 2\}$$

Der ExG liegt in einem Wertebereich zwischen -2 und 2 (Torres-Sánchez, López-Granados & Peña, 2015). Ähnlich wie beim NDVI werden negative Zahlen als vegetationslose und positive Werte als vegetationsbedeckte Bereiche eingeteilt. Der Schwellenwert für die Reklassifizierung wurde hier auf 0.03 erhöht, da sonst zu viele schwachbedeckte Grasflächen als vegetationslos deklariert würden (Abb. 8). Torres-Sánchez et al. (2015) erzielten mit dem ExG die besten Klassifizierungsergebnisse.

Vor der Einspeisung in den Bildklassifizierungsablauf wurden alle Layer auf dieselbe Grösse von ca. 46.6 ha zugeschnitten, damit die verzehrten und unscharfen Ränder die Resultate nicht negativ beeinflussten.




Abb. 8: Darstellung der zwei Vegetationsindizes ExG (rechts) und NDVI (links). Rote Bereiche sind vegetationslose und grün sind Flächen mit Vegetation.

2.3 Datenverarbeitung

Damit aus dem RGB Orthomosaik und der multispektralen Reflektionskarte thematische Karten entstehen, werden die generierten Multiband-Raster-Bilder einer überwachten, objektbasierten Bildklassifizierung unterzogen. Überwacht heisst, dass die Trainingsgebiete vom Anwender selbst erfasst werden. Dabei führt der Klassifikationsassistent von ArcGIS Pro den Anwender durch vier generelle Arbeitsschritte.

1. Segmentation
2. Trainingsgebiet Manager
3. Klassifikation
4. Genauigkeitsanalyse

Die einzelnen Schritte werden nachstehend zusammenfassend erklärt (verändert nach Esri Inc., 2019b). Die RGB und multispektralen Daten durchliefen zwar denselben Ablauf, mussten aber wegen unterschiedlicher Auflösungen getrennt verarbeitet werden. Detaillierte Angaben zu den Werkzeugen und Parametern sind im Anhang C aufgeführt.

2.3.1 Segmentation

Mit der Mean-Shift Segmentierung werden nahe gelegene Pixel zu Segmenten, sogenannten Superpixeln, gruppiert. Dabei definieren die Einstellungen der drei Parameter: Spektraldetail, räumliches Detail und die minimale Segmentgrösse, wie der Detailumfang von Bildelementen aussehen soll. In solch komplexen Bildern mit verschiedenen in sich übergehenden Vegetationsstrukturen, wie den vorliegenden, werden die räumlichen und spektralen Werte auf die höchste Stufe gesetzt (RGB=20; multispektral = 20). Der dritte Parameter richtete sich nach der minimalen Kartenerstellungseinheit (RGB = 90, multispektral = 20). Die aus der Segmentierung entstandenen ähnlichen Bereiche wurden dann als Objekte gruppiert (Abb.9).



Abb. 9: Beispiel einer Segmentierung (rechts) von Zwergsträuchern des RGB-Orthomosaiks (links).

2.3.2 Trainingsgebiet-Manager

Im Trainingsgebiet-Manager wurden pro Klasse ca. 30 Testgebiete ausgewählt und zugewiesen. Die Auswahl der Trainingsgebiete basierte einerseits auf den Informationen aus der terrestrischen Begehung (Referenzpunkt aus Abbildung 4) und andererseits auf visueller Interpretation des Orthomosaik. Es wurde zudem darauf geachtet, dass die Trainingsgebiete pro Klasse soweit möglich über das ganze Bild verteilt waren. Dies garantierte eine bessere Abdeckung der verschiedenen Reflexionsgrade der Klassen.

2.3.3 Klassifikation

Als Klassifizierungswerkzeug wurde der Support Vector Machine (SVM) Klassifikator eingesetzt (Abb. 10). Dieser wird in der Forschung häufig verwendet und benötigt beispielsweise gegenüber der Maximum Likelihood-Klassifizierung eine weniger ausgewogene Anzahl Trainingsgebiete pro Klasse sowie keine normale Verteilung der Daten (Durfee et al., 2019; Esri Inc., 2019b). Burai, Deák, Valkó & Tomor (2015) haben mit SVM bei ihren Untersuchungen ebenfalls gute Erfahrungen gemacht. Es folgte ein Vergleich zwischen dem klassifizierten Raster-Bild, dem Orthomosaik und dem zugehörigen segmentierten Layer. Zudem wurde die Genauigkeit der Trainingsgebiete berechnet. Bei zu hoher Falschklassifikation mussten die Trainingsgebiete angepasst werden. Dieser Vorgang wiederholte sich, bis ein zufriedenstellendes Resultat vorlag. Nach der Klassifikation konnten bei Bedarf einzelne Klassen gemäss Klassifikationsschema zusammengefasst werden. Gab es am Schluss dennoch klare Falschklassifikationen, hat eine manuelle Reklassifikation einzelner Segmente oder Bereiche geholfen. Das Zusammenführen und die Reklassifikation konnten nur innerhalb des Klassifikationsassistenten durchgeführt werden und waren nicht als einzelne Werkzeuge verfügbar.




Abb. 10: Beispiele verschiedener Layer Ausschnitte: 1. Orthomosaik, 2. Segmentiertes Bild, 3. Höhenmodell, 4. Klassifikation.

2.3.4 Genauigkeitsanalyse

Basierend auf dem Klassifikationsergebnis wird eine zufällige Auswahl an Punkten generiert. Anschliessend werden die Punkte über das Orthomosaik gelegt und die Attribut Tabelle mit den realen Klassen ergänzt. In einer Konfusionsmatrix werden die beiden Werte gegenübergestellt. Daraus resultiert ein Kappa-Übereinstimmungsindex welcher die Gesamtgenauigkeit zwischen den er klassifizierten Karte und den Referenzdaten angibt.

2.3.5 (i) Einteilung in Lebensräume

Um herauszufinden, wie weit das Orthomosaik und die Reflektionskarte in Lebensräume eingeteilt werden können, durchliefen beide Datensätze die ersten drei Schritte des Klassifikationsprozesses (Abb. 10). Die Ergebnisse wurden mit dem Orthomosaik verglichen. Da die beiden Kamertypen S.O.D.A. und Parrot Sequoia+ nicht die gleiche Auflösung haben, waren die Layer der beiden Datensätze nicht deckungsgleich. Das heisst die Trainingsgebiete aus dem RGB-Datensatz sind in den multispektralen Daten verschoben und vertreten ihre Klassen nicht mehr adäquat. Aus diesem Grund wurde versucht, die Layer mittels Georeferenzierung genau übereinander zu legen. Ein ganzheitliches Resultat war nicht möglich, weshalb die Trainingsgebiete einzeln überprüft und angepasst wurden (Abb. 11).




Abb. 11: Beispiel eines ursprünglichen Trainingsgebiet (hellblau) aus der Klasse offener Boden der multispektralen Reflektionskarte, welches verschoben werden musste, damit es wieder auf dem Weg anstatt auf der Wiese liegt.

Zudem wurden die Trainingsgebiete auf Repräsentationsgenauigkeit ihrer Klasse inspiziert und wiederum angepasst. Dabei war wichtig, darauf zu achten, dass informationslose Löcher (No-Data-Values Bereiche) nicht in Trainingsgebieten vorkamen, um spätere Fehler auszuschliessen. Bei diesen Löchern handelte es sich um Rekonstruktionsfehler, die während der Vorverarbeitung in Pix4D entstanden. Nach der Klassifikation wurde der Vorgang wiederholt, bis sich für beide Datensätze ein zufriedenstellendes Resultat ergab. Mit Hilfe der Anleitung von Dietl et al. (1981) konnten Polygone um die klassifizierten Lebensräume des RGB Bildes gezogen werden. Zur Überprüfung der Grenzziehung, wurde der Polygon-Layer auf das Orthomosaik gelegt und mit den Referenzpunkten verglichen. Der gleiche Polygon-Layer wurde danach auf die multispektralen Daten gelegt. Die neuen Grenzen wurden zudem mit den Ergebnissen von K. Edelkraut 2017 verglichen.

2.3.6 (ii) Ermittlung der produktiven Weidefläche

Aus dem RGB Orthomosaik wurde mit Hilfe des CHM-Layer die Strauch- und Baumschicht herausgeschnitten. Dem Gesamtbild werden dadurch Grünanteile entzogen, was die Möglichkeit der Falschklassifikation von Weideland minimierte. In einem nächsten Schritt wurden die vom ExG Layer ausgewiesenen vegetationslosen Flächen, wie Steine und offener Boden, vom Orthomosaik entfernt. Je weniger irrelevante Informationen bzw. Farbwerte vorhanden sind, desto besser konnte klassifiziert werden. Der Rest der unproduktiven Weidefläche kann aufgrund mangelnder Genauigkeit des CHM Layer nicht herausgeschnitten werden. Da sie keinen Futterwert haben, sind sie zur Klasse 'unproduktiv' zusammengefasst worden. Die Bergfettweiden mit höherem Futterwert, die Alpinen Magerrasen und die Lägerstellen mit geringerem Futterwert ergaben die Klasse 'produktiv'. Im Anschluss wurden die angepassten BFF-Teilflächen über das 'Produktiv / Unproduktiv' Bild gelegt. Wald und Krummholzgebüsch dominierte Randbereiche, welche nicht als BFF ausgewiesen sind, wurden abgeschnitten. Zur Flächenberechnung wird das Rasterbild in ein Vektorbild umgewandelt.

2.3.7 (iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

Die Fragestellung (iii) versucht herauszufinden, ob jeder Lebensraum ein individuelles Farbspektrum hat, welches beispielsweise in einer Datenbank gespeichert werden könnte und künftigen Luftbilduntersuchungen als Vergleich vorliegen würde. Untersuchungen könnten so um ein Vielfaches vereinfacht werden. Hierzu wurde aus den Trainingsgebieten ein Spektralprofil pro Klasse erstellt. In einer Grafik können die Farbspektren der einzelnen Klassen miteinander verglichen werden. Verlaufen die Linien nahe bei einander, decken die Lebensräume einen ähnlichen Spektralbereich ab. Weisen sie klare Abweichungen auf, ist es möglich sie zu differenzieren.

3 Resultate

3.1 (i) Einteilung in Lebensräume

RGB Datensatz

Die Abbildung 13 auf der nächsten Seite zeigt die durch die RGB Bildklassifizierung ausgewiesenen Lebensräume. Die dunkelblauen Linien stellen die Polygone bzw. Lebensräume dar. Die grauen Bereiche sind die vegetationslosen Flächen: Steine und offener Boden sowie die Baum- und Strauchschichten, welche vorgängig ausgeschnitten wurden. Jedes Polygon stellt aufgrund des Klassifikationsergebnisses einen Lebensraum dar, der sich von den Nachbarsflächen durch eine optische, mengenmässige Zu- oder Abnahme anderer Klassen unterscheiden lässt.

Die nährstoffreicheren Bergfettweiden nehmen mit zunehmender Höhe ab und die mageren Alpinen Rasen nehmen zu. Die alpinen Windheiden sind wie erwartet auf ausgesetzten Kuppen in höher gelegenen Bereichen zu finden. Auch Zwergsträucher siedeln sich lieber auf Kuppen an, so kann anhand ihrer Verteilung auf der südwestlichen Hälfte des Bildes gut erkannt werden, wie sich das Terrain faltet (Abb. 12 und Abb. 13).




Abb. 12: Rechts zeigt im Vordergrund eine Kuppe mit alpiner Windheide, worauf eine Mulde und eine erneute Kuppe, welche von Zwergsträuchern besetzt ist. Links zeigt die gleiche Stelle als Klassifikation von oben. Die Farblegende befindet sich auf der klassierten Lebensraumkarte Abb. 13.

Demgegenüber ist die Verteilung der Klassen am nordöstlichen Bildrand (Abb. 13) eher heterogen, was zu der Übergangsregion zwischen Weide, Zwergsträuchern, Krummholzgebüsch und Wald passt. Am gleichen Rand sind die grauen Flächen sichtlich grösser. Das zeigt, dass die Baumgrenze und der Krummholzgürtel durch die Karte verlaufen. In der viereckigen Einbuchtung der Karte ist weiter ersichtlich, dass Krummholzgebüsch fälschlicherweise als Lägerstellen klassifiziert werden. Die restlichen Flächen der Lägerstellen und die Alpenrosen als einzige rote Bildobjekte weisen ein gutes Resultat auf. Allgemein konnte das Gesamtergebnis durch den Abzug der grauen Flächen, sprich das Entfernen von ähnlich grüner Vegetation, wesentlich verbessert werden.

Lebensraumkarte Alp Muotselvas RGB




Abb. 13: Lebensraumkarte generiert aus der überwachten objektbasierten Bildklassifizierung (OBIA).

Genauigkeitsanalyse

In den Spalten stehen die wirklichen Klassen der Trainingsgebiete und in den Zeilen die Vorhersage des Klassifikators. Der Kappa-Übereinstimmungsindex gibt an, wie präzise das Klassifikationsergebnis ist. 65% ist ein tiefer Wert. Da nicht alle Steine und offenen Bodenstellen entfernt werden konnten, wurden Punkte aus der Genauigkeitsbewertung, die als Vegetationsklasse klassifiziert wurden, gelöscht. Von ursprünglich 500 Punkten konnten 465 für die Analyse verwendet werden.

Tab. 4: Konfusionsmatrix der RGB-Klassifikation ergibt einen Kappa-Übereinstimmungsindex und eine Gesamtgenauigkeit zwischen der klassifizierten Karte und dem Orthomosaik an.

Referenzpunkteschema: Equalized stratified random

Klassen Name	ClassValue	C_1	C_51	C_52	C_54	C_55	C_61	C_62	C_67	Total	U_Acc.	Kappa
extrahiert	C_1	62	0	0	0	0	0	0	0	62	100%	
Zwergsträucher	C_51	0	50	1	0	0	3	2	7	63	79%	
Alpenrosen	C_52	2	5	28	6	0	2	5	0	48	58%	
alpine Windheide	C_54	0	8	5	35	1	0	5	0	54	65%	
Krummholzgebüsch	C_55	1	7	0	0	42	2	0	5	59	71%	
Lägerstellen	C_61	1	12	0	0	19	28	0	1	61	46%	
alpine Magerrasen	C_62	1	6	2	1	1	1	43	2	57	75%	
Bergfettweide	C_67	0	18	0	0	4	3	1	34	61	56%	
Total		67	106	36	42	67	39	56	49	465		
P_Accuracy		93%	47%	78%	83%	63%	72%	77%	69%		69%	
Kappa												65%

Die Alpenrosen wurden mit ihrem Rotton oft als alpine Windheiden oder offenen Boden falsch klassifiziert. Krummholzgebüsch mit satten Grüntönen ist meist fälschlicherweise als Lägerstellen ausgewiesen worden. Oft verwechselt wurden auch die helleren Zwergsträucher mit der grünen Bergfettweide. Im Allgemeinen konnten die extrahierte Klasse, die Krummholzgebüsche und die alpinen Magerrasen am besten klassifiziert werden.

Vergleich Lebensraumgrenzen

Beim Übereinanderlegen des Lebensraumpolygon-Layers auf das Orthomosaik, war eine farbliche Veränderung zu den Nachbarspolygonen in den meisten Fällen ersichtlich, was auf ein erfolgreiches Ergebnis hindeutet (Abb. 14). Wird dieses Ergebnis mit den 2017 kartierten Lebensraumgrenzen (dunkelrot) überlagert (Abb. 15), fällt auf, dass die neuen Lebensräume (dunkelblau) oft kleiner erfasst wurden. Liegen die beiden Grenzfürhungen nahe beieinander, sind die Unterschiede der Lebensräume wahrscheinlich schwer zu definieren.

Überlagerung Lebensraumgrenzen aus RGB-Datensatz




Abb. 14: Der Polygon-Layer wurde über das Orthomosaik gelegt, um zu überprüfen, wie gut die Lebesraumeinteilung der Klassifikation erfolgte.

Vergleich Lebensraumgrenzen




Abb. 15: Zum Vergleich der gezogenen Grenzen wurde über die Abbildung 13, die Lebensraumgrenzen von 2017 darübergelegt. Auffällig ist, dass die neuen teilweise kleiner sind.

Multispektraler Datensatz

Für den multispektralen Datensatz erstellte Pix4D kein eigenes Höhenmodell. Das Höhenmodell aus dem RGB Datensatz war einerseits wegen unterschiedlicher Auflösung nicht deckungsgleich und konnte andererseits mittels georeferenzieren nicht genau übereinandergelegt werden (Kap. 2.3.5). Um keine falschen Bereiche zu extrahieren, wurden beim multispektralen Datensatz nur die vegetationslosen Flächen, berechnet aus dem NDVI, entfernt. Die Klasse der Krummholzgebüsche und die Zwergsträucher wurden deutlich überklassifiziert. Die Alpenrosen werden hier stellenweise dichter ausgewiesen und ebenfalls überklassifiziert. Demgegenüber wurden die Bergfettweideflächen und die alpinen Windheiden unterklassifiziert. Die Ausdehnung der Lägerstellen scheint geringer ausgefallen zu sein als in der RGG-Klassifikation und dem Orthomosaik (Abb. 15). Sehr gute Ergebnisse lieferte die Klassifizierung der Bäume bzw. des Waldes.




Abb. 16: Als Vergleich wurde der Polygon-Layer des RGB Datensatzes über die Bildklassifizierung des multispektralen Datensatz gelegt. Die Grenzen stimmen teilweise nicht überein. Krummholzgebüsch und andere Klassen wurden deutlich überklassifiziert.

3.2 (ii) Ermittlung der produktiven Weidefläche

Die generierten Lebensraumkarten bildeten die Basis für die Berechnung der produktiven und unproduktiven Flächenanteile.

RGB Datensatz

Die Abbildung 17 zeigt die auf das Untersuchungsgebiet angepassten BFF-Teilflächen. Ihre Gesamtgrösse beträgt ca. 40.8 ha. In blau sind die unproduktiven Flächen dargestellt, welche sich aus den Klassen Zwergsträucher, Alpenrosen und alpinen Windheiden zusammensetzen. Grün zeigt die produktiven Weideflächen mit Futterwert, die aus den Alpinen Magerrasen, den Bergfettweiden und den Lägerstellen bestehen. Von der Gesamtgrösse sind 30% (12.2 ha) unproduktiv und 63% (25.7 ha) produktives Weideland. Die extrahierte Baum- und Strauchschicht machten zusammen mit den vegetationslosen Flächen aus dem ExG 7% (2.9 ha) aus. Sie sind in grau dargestellt.




Abb. 17: Übersicht der ausgeschnittenen BFF-Teilflächen. Die Fläche eins und sechs stellen keine BFF-Qualitätsflächen dar.




Abb. 18: Darstellung der prozentualen Verteilung der produktiven, unproduktiven und extrahierten Flächen aus dem RGB Datensatz. In den Balken ist zudem die Fläche in ha angegeben.

Die Teilflächen drei und vier enthielten mit 73% und 77% am meisten produktives Weideland (Abb. 18). Die Teilfläche sechs hatte mit 41% nicht nur den tiefsten Anteil produktives Weideland, sondern mit 26% auch den höchsten Anteil extrahierter Fläche. Die restlichen fünf Flächen haben nicht mehr ihre ursprüngliche BFF-Grösse, weil sie auf das Untersuchungsgebiet angepasst wurden. In der Fläche eins, welche gemäss Erhebungsdaten keine BFF-Qualität hat, und zwei ist gut die Hälfte (beide 52%) produktives Weideland. Die Flächen fünf, sieben und acht erreichen beinahe 60%. In den tiefer gelegenen Flächen sind die extrahierte Flächen grösser.

Multispektraler Datensatz

Die Grösse aller BFF-Teilflächen zusammen beträgt in Abbildung 19 ebenfalls 40.8 ha. Die unproduktiven, blauen Flächen setzten sich aus den Klassen Wald, Krummholzgebüsch, Zwergsträucher, Alpenrosen und den alpinen Windheiden zusammen. Gemeinsam bilden sie eine Fläche von 22.6 ha (55%). Die grünen, produktiven Flächen bestehen wie bei den RGB-Daten aus alpinem Magerrasen, Bergfettweiden und Lägerstellen und beliefen sich auf 17.1 ha. Das sind 42% des Untersuchungsgebiets. Die grauen, extrahierten Flächen stellen hier nur die vegetationslosen Bereiche aus Stein oder offenem Boden dar und betrugen 1.1 ha.




Abb. 19: Darstellung der prozentualen Verteilung der produktiven, unproduktiven und extrahierten Flächen aus dem MS Datensatz. In den Balken ist zudem die Fläche in ha angegeben.

Im Vergleich zu den Ergebnissen aus den RGB-Daten ist hier der Anteil produktives Weideland wesentlich kleiner. Nur die Flächen drei (55%), vier (51%) und sieben (50%) wiesen etwa die Hälfte als produktives Weideland aus, alle anderen lagen weit darunter.

3.3 (iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

In ArcGIS kann für jede Klasse ein Spektrales Profil erstellt werden, welches einen Durchschnitt der spezifischen Farbwerte abbildet. In den ersten Bildklassifizierungsdurchläufen wurden pro Klasse knapp 60 Proben ausgewählt. Aufgrund der hohen Datenmengen konnte der Rechner in absehbarer Zeit kein Profil für auch nur eine Klasse erstellen. In einem zweiten Schritt wurden die Trainingsgebiete auf gut die Hälfte reduziert und in einem dritten auf knapp zehn runtergesetzt. Trotz dieser Massnahme konnte kein Ergebnis erzielt werden. Ein Spektralprofil einzelner Trainingsgebiete ist aufgrund verändernder Farbtöne nicht repräsentativ.

4 Diskussion

Diese Arbeit prüft, ob der Einsatz von Drohnen zur Abgrenzung von Lebensräumen im Sömerungsgebiet hilfreich ist. Dafür wurden Luftbildaufnahmen der Alp Muotselfas einer überwachten Objekt-basierten Bildklassifizierung unterzogen, um eine qualitative Lebensraumkarte zu erhalten, anhand jener die produktive Weidefläche berechnet werden kann.

Oft kann sich im Wind bewegende Vegetation während des Flugs nicht identifiziert werden (Carrivick et al., 2016). Der leichte Wind während der Befliegung hatte indes keinen negativen Einfluss auf die Pix4D Ausgabeprodukte. Allerdings konnten nicht alle weissen Steinoberflächen vollständig rekonstruiert werden, weshalb es zu informationslosen Löchern im Orthomosaik gekommen ist. Gemäss Carrivick et al. (2016) ist das vor allem bei stark reflektierenden Landformen wie Stein, Glas oder Schnee eine bekannte Schwierigkeit, die erst bei der Datenverarbeitung im Büro bekannt wird. Methoden der Georeferenzierung, wie die PPK-Methode, sind für solche Fälle unerlässlich. Hier handelt es sich bei den informationslosen Bereichen lediglich um kleine Pixelgruppen innerhalb der Klasse Stein, welche schliesslich extrahiert wurden. Bei einer Weiterverarbeitung der Daten ist darauf zu achten, dass solche Löcher nicht innerhalb von Trainingsgebieten liegen, um spätere Klassifikationsfehler zu vermeiden.

Die Erfassung von Referenzpunkten bei der terrestrischen Begehung ist sehr hilfreich, da nicht alle evidenten Veränderungen im Gelände auch auf dem Orthomosaik ersichtlich waren (z.B. Anhäufung von weissen Flechten). Ihre ausführliche Dokumentation ist deshalb wichtig, damit die Trainingsgebiete später am richtigen Ort gesetzt werden können. Die Map Marker-App ist privat entwickelt worden und in gewissen Bereichen (Fotodokumentation, Daten-Synchronisation usw.) noch nicht ausgereift. In künftige Arbeiten wäre zu prüfen, ob die Verwendung der kostenlosen ArcGIS Collector App für eine botanische Erfassung geeigneter wäre. Allenfalls könnten Referenzpunkte direkt einem vordefinierten Klassifikationsschema zugeordnet werden. Eine Erfassung der Indikatorpflanzen wäre ebenfalls denkbar. Da die Collector App von derselben Herstellergruppe ist, ist anzunehmen, dass die Datensynchronisation kompatibler wäre. Eine elektronische Datenerfassung während der terrestrischen Begehung wird bisher kaum angewendet.

Einen bedeutenden Einfluss auf die Ergebnisse haben die Einstellungen der Segmentierungsparameter. Sie bestimmen die Grösse, Form und räumliche Verteilung der Bildobjekte und nur ihre richtige Kombination ergibt eine gute Basis für die Bildklassifikation (Hay, Castilla, Wulder & Ruiz-Gallardo, 2005; Laliberte et al., 2011). Im multispektralen Datensatz führte eine Erhöhung der minimalen Segmentgrösse von 10 auf 20 zu bedeutend besseren Klassifikationsergebnissen. Die Überklassifikation von Alpenrosen und anderen Zwergsträuchern konnte deutlich reduziert werden (Abb. 20).



Abb. 20: Unterschied der Klassifikationsergebnisse des multispektralen Datensatzes bei Erhöhung der minimalen Segmentgrösse 10 (links) auf 20 (rechts). Alpenrosen und andere Zwergsträucher werden deutlich weniger überklassifiziert.

Die Aufbereitung der Luftbilddaten in Pix4D mit der Structure-from-Motion-Methode lieferte qualitativ gute Ergebnisse. Carrivick et al. (2016) meinen, dass SfM in der Anschaffung der Hard- und Software billiger ist. Zurzeit ist die effiziente Visualisierung der SfM-Daten in einem Standard-Industrie-GIS aufgrund der teils grossen Datenmengen noch problematisch. Dennoch ist die Anwendung von SfM, aufgrund der einfachen Bedienung und der qualitativen Ergebnisse in künftigen Untersuchungen sehr zu empfehlen.

4.1 (i) Einteilung in Lebensräume

Aus der terrestrischen Begehung konnten Referenzpunkte gesammelt werden, welche in der Bildklassifizierung aufgrund von Farbwerten für die Zuweisen der Klassen geholfen haben. Daraus ist eine thematische Karte entstanden, welche die Verteilung von Lebensräumen zeigt.

Werden die Klassifizierungsergebnisse des RGB- und des multispektralen Datensatzes mit dem Orthomosaik verglichen, zeigen die RGB-Ergebnisse ein genaueres Abbild (Abb. 21). Krummholzgebüsch, Alpenrosen, Zwergsträucher wurden in den multispektralen Daten überklassifiziert. Bergfettweiden, alpine Windheiden und Lägerstellen wurden unterklassifiziert. Einzig der Wald lieferte wesentlich bessere Klassifizierungsergebnisse in den multispektralen Resultaten. Ein Grund dafür sind die in der Methodik erwähnten unterschiedlichen Auflösungen der beiden Kamerateypen (Torres-Sánchez et al., 2015). Die tiefere Auflösung führte zur Verschiebung der Trainingsgebiete und zu weniger deutlichen Bildobjekten. An ihren Rändern entstehen sogenannte Mischpixel, welche keiner eindeutigen Klasse zugeordnet werden können. Je kleiner die Bildobjekte sind, desto mehr Mischpixel gibt es. Zur Berichtigung könnten die multispektralen Daten nochmals neu in Pix4D eingelesen werden, mit Passpunkten aus dem RGB-Daten versehen und neu verarbeitet. Da Komárek et al. (2018) in ihren Bildklassifizierungen eines Arboretums mit multispektralen Daten Pflanzen teils bis auf Spezies-Level besser klassifizieren konnten als mit den RGB-Daten, wäre es interessant, den gleichen Flug

entweder mit geringerer Flughöhe (Torres-Sánchez et al., 2014) oder mit einem bessern multispektralen Sensor zu wiederholen. Auch Ahmed et al. (2017) erzielten mit den RGB-Daten tiefere Klassifikationsgenauigkeit als mit multispektralen. Die Auflösung ihres RGB-Sensors war um 2 MB kleiner (Sony DSC-WX220, 18MB), für die multispektralen Bilder wurde ebenfalls die Parrot Sequoia+ verwendet. Eine andere Möglichkeit zur Reduktion der Mischpixel wäre, bei der Segmentierung die minimale Grösse herabzusetzen (Torres-Sánchez et al., 2015). Auf diese Weise setzten sich die kleineren Objekte aus einem repräsentativeren Farbspektrum zusammen. Allerdings kann sich das wie erfahren negativ auf grössere Objekte auswirken.

Die Vegetationsindizes ExG und NDVI liefern wie bei Viljanen et al. (2018) auch hier gute Resultate zur Unterscheidung von bedeckten und vegetationslosen Bereichen. Die anschließende Entnahme dieser vegetationslosen Bereiche basiert auf dem gleichen Prinzip der Minderung von Mischpixeln, was primär die Klassifizierung von hellen Lebensräumen wie beispielsweise den alpinen Magerrasen verbessert. Viljanen et al. (2018) verwenden in ihrer Untersuchung mehrere Indizes gleichzeitig und erhalten so die besten Resultate. Aus welchen die beste Kombination für die Bildklassifizierung entsteht, ist meist für jedes Projekt unterschiedlich und muss durch Anwendung eruiert werden.

Bei beiden Datensätzen wurde anfangs vor allem die Strauchschicht überklassifiziert. Bei den RGB Daten gab es zudem Schwierigkeiten mit der Klassifikation von Wald, welcher im Ergebnis vor der Reklassifikation fälschlicherweise über die gesamte Untersuchungsfläche verteilt war. Gemäss Ahmed et al. (2017) ist dies ein bekanntes Problem und beruht auf der ähnlichen spektralen Farbzusammensetzung der Vegetationsgesellschaften. Der Abzug des Höhenmodells hat hier zu sehr positiven Ergebnissen geführt.

Aus diesen Ergebnissen lässt sich schliessen, dass der Einbezug von zusätzlichen Daten (Vegetationsindizes, Höhenmodell) die Bildklassifikation wesentlich verbessert. Komárek et al. (2018) haben zudem bessere Resultate mit Wärmebildkameras erreicht, Viljanen et al. (2018) mit der Kombination verschiedener Vegetationsindizes, Höhenmodellen und Wärmebildkameras. Mit einem guten Höhenmodell sollte es möglich sein, die groben Vegetationsschichten so voneinander zu trennen, dass jede Schicht separat klassifiziert werden kann. Ob dies zu verbesserten Resultaten führt, sollte Gegenstand künftiger Untersuchungen sein.

Es wäre zu prüfen, ob eine zusätzliche Befliegung gegen Ende des Sommers einen positiven Effekt auf die Unterscheidung der Lebensräume hat. Zu diesem Zeitpunkt verändern die Vegetationsgesellschaften die Farbe und reduzieren die Produktion des Chlorophylls. Wie Torres-Sánchez et al. (2014) schreiben, verändert das die Reflexionsgrade in den Blattstrukturen. Eine Differenzierung der Pflanzen bzw. der Lebensräume zu dieser Jahreszeit könnte deshalb speziell bei den multispektralen Daten zu besseren Resultaten führen (Durfee et al., 2019; Torres-Sánchez et al., 2014).




Abb. 21: Die Klassifikationsergebnisse der RGB- und multispektralen Daten werden hier anhand von vier Beispielen verglichen. (e) stellt ein unglaublich gutes Abbild von (a) dar. In (f) ist die Falschklassifikation von Alpenrosen und die Minderklassifikation von Lägerstellen ersichtlich. (g) zeigt die Entnahme von Vegetationsschichten und in (h) ist die heterogene Verteilung in strukturreichem Gelände ersichtlich. Die multispektralen Daten zeigen ein weniger genaues Abbild des Orthomosaiks.

Der Kappa-Übereinstimmungsindex (65%) und die Gesamtgenauigkeit (69%) sind eher tief ausgefallen. Da die zufällig generierten Punkte aus der Genauigkeitsbewertung manuell den tatsächlichen Klassen zugeordnet werden, können Fehler in der Bearbeitung der Daten entstehen. Alpenrosen konnten gegenüber alpinen Windheiden, den restlichen Zwergsträuchern sowie offenen Bodenstellen, welche durch den ExG nicht entfernt wurden, am schlechtesten abgegrenzt werden. Die bläulichen, silbernen Weiden der Klasse Krummholzgebüsch werden gut klassifiziert, hingegen werden die Grünerlen oft fälschlicherweise den Zwergsträuchern zugeordnet. Bergfettweiden sind nährstoffreicher und grüner als alpine Magerrasen, weshalb die Klassifizierung in ihren Übergangsbereichen schwierig ist. Die Konfusionsmatrix zeigt auf, welche Klassen schwerer und besser abgrenzbar sind. Diese Ergebnisse sollten in künftigen Untersuchungen in Sömmerungsgebieten berücksichtigt werden. Die Auflösung des Orthomosaiks schränkt teilweise die sichere Zuweisung einer Klasse ein, weshalb unter Verwendung von hyperspektralen Sensoren die Gesamtgenauigkeit steigen sollte (Govender, Chetty, Nair & Bulcock, 2008; Komárek et al., 2018).

4.2 (ii) Ermittlung der produktiven Weidefläche

Terrestrische Begehungen zur Kartierung der BFF in Sömmerungsgebieten sind zeitaufwändig und nicht immer einfach möglich. Es wurde vermutet, dass der Einsatz von Drohnen ein vielversprechendes Hilfsmittel bei der Ersterfassung oder für die Überwachung von Veränderungen sein könnte.

Die aus der Lebensraumeinteilung entstandene thematische Karte dient als Ausgangslage für die Berechnung der produktiven und unproduktiven Flächen. Alle ausgewiesenen BFF-Teilflächen der RGB Daten erreichten einen produktiven Anteil zwischen 50% bis 80%. Es ist deutlich zu erkennen, dass in heterogenen Flächen der Anteil an unproduktivem Weideland grösser ist. Das schrittweise Entfernen von Daten hat sich auch für die Beantworten dieser Fragestellung (ii) als Methode bewährt.

Die BFF-Teilflächen drei und vier entsprechen derselben Grösse wie in den Erhebungsdaten von 2017, die anderen wurden auf das Untersuchungsgebiet verkleinert. Die Qualitätsanteile von 2017 wurden nach der von AGRIDEA beschriebenen Methode erfasst (Hedinger, 2014). Der Qualitätsanteil beinhaltet Weidefläche mit BFF-Qualität (6 Indikatorpflanzen). Die unproduktiven Elemente (Steine, Weg, Zwergsträucher, Disteln usw.) werden nur in Bezug auf den Qualitätsanteil geschätzt, nicht auf die ganze Teilfläche. In den Ergebnissen von 2019 sind die un- / produktiven und extrahierten Anteile in Bezug auf die gesamte BFF-Teilfläche gerechnet. Die Indikatorpflanzen wurden nicht berücksichtigt. Ein direkter Vergleich ist aufgrund der unterschiedlichen Methoden nicht möglich, weshalb keine abschliessende Genauigkeit dieser Resultate angegeben werden kann. Es wird aber vermutet, dass der um 7% höhere Anteil

produktiver Fläche in der Teilfläche vier deshalb zustande kommt, weil feuchte, nährstoffreiche Mulden und Lagerstellen zu den produktiven Flächen zählen (Tab. 4). Dies erklärt aber nicht, den um 17% tieferen in der Fläche drei. Generell sind die produktiven Flächen in den vorliegenden Ergebnissen tiefer. Eine Erklärung dafür könnte sein, dass mit den Vegetationsindizes viele kleine Steine entfernt werden, welche bei der Schätzung wahrscheinlich kaum berücksichtigt werden können. Die Fläche eins wäre eigentlich keine BFF-Fläche, zeigt allerdings in der auf das Untersuchungsgebiet angepassten Form einen produktiven Anteil von 52%. Wäre diese BFF-Teilfläche in Realität kleiner, könnte sie mit dem Vorkommen der Indikatorpflanzen beitragsberechtigt sein. Mit der angewandten Methode würden dementsprechend die Abzüge für unproduktive Flächen höher, dafür könnte aufgrund der Resultate die BFF-Grenzziehung angepasst werden und mehr Qualitätsflächen ausgewiesen. Ein Gewinn für beide Parteien: Landwirt und Kanton.

Tab. 5 und 6: Gegenüberstellung der 2017 erfassten Qualitätsanteile und den RGB-Ergebnissen aus 2019. Fläche eins und sechs haben keine BFF-Qualität und zeigen deshalb oben 0%. Ein direkter Vergleich ist aufgrund verschiedener Methoden nicht möglich.

Erhebungsdaten 2017

Teilflächennummer	1	2	3	4	5	6	7	8
Qualitätsanteil	0%	80%	90%	70%	80%	0%	80%	100%
unproduktiv Anteil der Testfläche	0%	20%	10%	20%	30%	0%	15%	50%
effektiver Abzug der Testfläche	0%	10%	0%	10%	20%	0%	5%	40%

RGB-Ergebnisse 2019

Teilflächennummer	1	2	3	4	5	6	7	8
produktiv	52%	52%	73%	77%	58%	41%	59%	58%
unproduktiv	35%	43%	23%	20%	34%	34%	31%	32%
extrahiert	13%	5%	4%	3%	8%	26%	10%	10%

In Bezug auf die Qualität der Untersuchungsflächen könnte die Erfassung einzelner Pflanzenarten helfen. Komárek et al. (2018) haben mit multispektralen Sensoren Arten in einem Arbo-retum bestimmt, Durfee et al. (2019) haben vegetative Veränderungen in der Landschaft aufgezeigt und Babbi et al. (2017) konnten in einem Gebiet die Verbreitung des invasiven Adlerfarns analysieren. Dabei handelt es sich hingegen um grössere, markantere Pflanzenobjekte. Ein Untersuchungsgebiet wie das vorliegende, ist durch die Verzahnung der Lebensräume viel komplexer. Die Erfassung einzelner Graslandarten ist mit der verwendeten Technologie nicht möglich.

Auch wenn mit der angewandten Methode die Qualitätsanteile nicht ermittelt werden konnten, können dennoch die unproduktiven Elemente berechnet anstatt geschätzt werden. Dies bedeutet eine Entlastung für Fachpersonen, welche nun ihre Resultate vor dem Landwirt und dem Kanton rechnerisch darlegen können.

4.3 (iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

Es wurde versucht aus den Trainingsgebieten pro Klasse ein Spektrales Profil zu erstellen, um den Lebensräumen ein spezifisches Farbspektrum zuzuweisen. Unglücklicherweise konnte der Rechner die grossen Datenmengen nicht verarbeiten.

Die dichten grünen Flecken in den Alpenen Magerrasen bestehen im Untersuchungsgebiet mehrheitlich aus Rasenschmiele und Alpen-Lieschgras, typische Feuchtwiesenvertreter (Abb. 22). Die Bilder (e) und (f) in Abbildung 20 zeigen, dass sie im Übergang zu den alpinen Rasen als Bergfettweide klassifiziert werden. An diesem Beispiel ist gut zu erkennen, dass die Dichte und die Zusammensetzung einen Einfluss auf die spektrale Farbzusammensetzung haben. In Lebensraumübergängen wird es demnach nicht möglich sein ein eindeutiges Spektralprofil zu erfassen. Die Alpenrosen können hier durch die roten Blüten sehr gut isoliert werden. Allerdings sieht das ausserhalb ihrer Blühphase anders aus. Da das Farbspektrum einer Pflanze, folglich auch eines Lebensraumes über die Jahreszeiten hinweg ändert, wird es schwierig, ein eindeutiges Farbspektrum überhaupt zu definieren (Govender et al., 2008).



Abb. 22: Ein Beispielbild aus dem Untersuchungsgebiet mit einem monotonen Rasenschmiele Bestand.

Lopatin, Fassnacht, Kattenborn & Schmidtlein (2017) haben herausgefunden, dass die Klassifikation von Grasslandarten auf Artniveau bei wenig komplexen Vegetationsstrukturen und hoher Auflösung möglich ist. Schon Jacobsen, Broge & Hansen nahmen 1995 einzelne Spektralprofile von Weizentypen auf. Beide verwenden dafür hochaufgelöste hyperspektrale Daten.

Hyperspektrale und multispektrale Daten nehmen Wellenlängen aus demselben elektromagnetischen Spektrum auf. Der Unterschied liegt in der Anzahl Spektralkanälen und ihren Abständen. Während multispektrale Bilder drei bis zehn Spektralkanäle haben, sind es bei hyperspektralen hunderte bis tausende, in einem engeren Abstand zwischen 10-20 nm (Burai et al., 2015; Govender et al., 2008). Dadurch dass die Wellenlängen der hyperspektralen Daten viel enger beieinanderliegen, kann ein viel kontinuierlicheres Spektralprofil von Pflanzen erfasst werden. In der Schweiz haben Psomas, Zimmermann, Kneubühler, Kellenberger & Itten

(2005) versucht, mit hyperspektralen Sensoren und verschiedener jahreszeitlichen Wachstumsphasen diverse Graslandtypen zu differenzieren. Die besten Ergebnisse resultierten durch das schrittweise Entfernen von Vegetationsschichten.

Die Identifikation spezifischer Farbspektren ist demnach ein aktuelles Thema an der Forschungsfront. Adão et al. (2017) haben in ihrer Untersuchung eine Liste mit den momentan gebräuchlichen hyperspektralen Sensoren, welche mit Drohnen verwendet werden können, zusammengestellt. Sie geben auch eine Zusammenfassung der Vor- und Nachteile in Zusammenhang mit der Arbeit von hyperspektralen Daten. Momentan sind diese Sensoren für eine breite Masse von Anwendern noch etwas teuer, mit dem technologischen Fortschritt wird sich dies aber bald ändern. Dann braucht es genügend Fachpersonen, die diese Daten einerseits aus Umweltsicht verstehen und andererseits mit technischem Wissen verarbeiten können.

4.4 Kontext zur Nachhaltigkeit

Wie zu Beginn dieser Arbeit bereits erwähnt, sind nach Lauber et al. (2017) Sömmerungsgebiete mitunter die artenreichsten Lebensräume der subalpinen und alpinen Höhenstufen. Sie liefern aber auch Nahrung, sind ein Wahrzeichen für die Schweizer Kulturlandschaft und bieten dem Menschen Raum für Erholung und Inspiration. Eine Verschlechterung der Biodiversität würde automatisch zu einer Abnahme dieser Ökosystemdienstleistungen führen (BAFU, 2017). Deshalb ist die Sicherung dieses Schweizer Naturkapitals sowohl in der Bundesverfassung (Art. 78, „Bundesverfassung der Schweizerischen Eidgenossenschaft (BV)“, 2000), als auch im Natur- und Heimatschutz Gesetz (Art. 18, „Bundesgesetz über den Natur- und Heimatschutz (NHG)“, 1967) verankert. Zudem haben Bund und Kantone mit der Inventarisierung und Finanzierung von BFF in Sömmerungsgebieten direkte Massnahmen zu deren Erhalt und Förderung ergriffen (BAFU, 2017). Der Einsatz von Drohnen hilft, diese Massnahmen auch über grössere und längere Zeiträume (Durfee et al., 2019), effizient und in guter Qualität durchzuführen. Damit soll im Sinne der Nachhaltigkeit die Vielfalt an Genen, Arten und Lebensräumen als existenzielle Grundlage für den Menschen, sein Leben und Wirtschaften heute und in Zukunft erhalten bleiben (BAFU, 2017).

4.5 Fazit

Die generierte Lebensraumkarte aus dem RGB-Datensatz widerspiegelt die Klassen erstaunlich gut. Basierend auf dem Orthomosaik und der Klassifikationsergebnisse kann vor einer terrestrischen Begehung eine erste Einschätzung über die Verteilung von Lebensräumen gewonnen werden. Eindeutige Flächen müssen, bis auf die Testflächen zur Identifikation der Indikatorpflanzen, nicht mehr genaustens abgelaufen und unproduktive Anteil nicht mehr geschätzt werden. Unklaren Bereichen kann von Anfang an mehr Aufmerksamkeit geschenkt werden. Die Ergebnisse zeigen auf, welche Klassen gut oder schwierig abgrenzbar sind. Vegetationsindizes und Höhenmodelle sowie die Entnahme von Daten steigern die Genauigkeit der Ergebnisse deutlich. Zudem ist davon auszugehen, dass mit hyperspektralen Daten noch bessere Resultate erzielt würden. Demzufolge ist der Einsatz von Drohnen zur Abgrenzung von Lebensräumen ein vielversprechendes Hilfsmittel und sollte weiterhin untersucht werden.

5 Literaturverzeichnis

- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R. et al. (2017). Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing*, 9(1110), 30.
<https://doi.org/10.3390/rs9111110>
- Babbi, M., Widmer, S., Ochsner, P. & Krüsi, B. (2017). Hilfe von oben: Erfassung von Adlerfarnbeständen mit Drohnen. *Vierteljahrsschrift der Naturforschenden Gesellschaft in Zürich*, 162(3/4), 10–11.
- BAFU. (2017). Biodiversität in der Schweiz: Zustand und Entwicklung. Ergebnisse des Überwachungssystems im Bereich Biodiversität, Stand 2016. Umwelt Zustand No. 1630. (S. 60). Bern: Bundesamt für Umwelt.
- Baltisberger, M., Nyffeler, R. & Widmer, A. (2013). Systematische Botanik (4. Auflage.). Zürich: vdf Hochschulverlag AG.
- Baumgärtel, A. & Landrock, H. (2018). Die Industriedrohne - der fliegende Roboter. Professionelle Drohnen und ihre Anwendung in der Industrie 4.0. Springer Vieweg.
- Benz, R. (2014a). Biodiversitätsförderflächen BFF Zeigerpflanzen im Sömmerungsgebiet. AGRIDEA.
- Benz, R. (2014b). Biodiversitätsförderung Qualitätsstufe II: Von artenreichen Grün- und Streuflächen im Sömmerungsgebiet gemäss Direktzahlungsverordnung (DZV). Merkblatt No. 2360. (S. 6). Lausanne: AGRIDEA.
- Blaschke, T. (2009). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote sensing*, (65), 2–16.
<https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Bundesamt für Landwirtschaft (BUWAL). (2018). Überblick: Direktzahlungen an Sömmerungs- und Gemeinschaftsweidebetriebe.
- Bundesverfassung der Schweizerischen Eidgenossenschaft (BV). (1. Januar 2000). SR 101 (Stand: 23. September 2018).
- Burai, P., Deák, B., Valkó, O. & Tomor, T. (2015). Classification of Herbaceous Vegetation Using Airborne Hyperspectral Imagery. *Remote Sensing*, (7), 2046–2066.
<https://doi.org/10.3390/rs70202046>
- Carrivick, J. L., Smith, M. W. & Quincey, D. J. (2016). Structure from Motion in the Geosciences. *New Analytical Methods in Earth and Environmental Science* (1. Auflage). Chichester, West Sussex, PO19 8SQ, UK: John Wiley & Sons Ltd.
- Christen, M., Guillaume, M., Jablonowski, P., Lenhart, P. & Moll, K. (2018). Zivile Drohnen - Herausforderungen und Perspektiven. vdf Hochschulverlag AG.
- Delarze, R., Gonseth, Y., Eggenberg, S. & Vust, M. (2015). Lebensräume der Schweiz (3. vollständig überarbeitete Auflage.). Bern: Ott.
- Dietl, W., Berger, P. & Ofner, M. (1981). Die Kartierung des Pflanzenstandortes und der futterbaulichen Nutzung von Naturwiesen. Zürich Reckenholz: Zürich: FAP + AGFF.
- Durfee, N., Ochoa, C. G. & Mata-Gonzalez, R. (2019). The Use of Low-Altitude UAV Imagery to Assess Western Juniper Density and Canopy Cover in Treated and Untreated Stands. *Forests*, 10(296). <https://doi.org/10.3390/f10040296>

- eMotion. (2019). Cheseaux-sur-Lausanne: senseFly.
- Esri Inc. (2019a). ArcGIS Pro. Redlands, California 92373-8100, USA.
- Esri Inc. (2019b). ArcGIS Pro Werkzeugreferenz. Redlands, California 92373-8100, USA.
Verfügbar unter: <https://pro.arcgis.com/de/pro-app/tool-reference/main/arcgis-pro-tool-reference.htm>
- Govender, M., Chetty, K., Naiken, V. & Bulcock, H. (2008). A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation. *Water SA*, 34(2). <https://doi.org/10.4314/wsa.v34i2.183634>
- Green, K., Congalton, R. G. & Tukman, M. (2017). *Imagery and GIS. Best Practices for Extracting Information from Imagery (1.)*. Redlands, California: Esri Press.
- Hay, G. J., Castilla, G., Wulder, M. & Ruiz-Gallardo, J. R. (2005). An automated object-based approach to the multiscale image segmentation of forest scenes. *International Journal of Applied Earth Observation and Geoinformation*, 7(4).
<https://doi.org/10.1016/j.jag.2005.06.005>
- Hedinger, C. (2014). Artenreiche Grün- und Streueflächen im Sömmerungsgebiet. Eine Beurteilungshilfe für Alpbewirtschaftende. AGRIDEA.
- Hunt Jr., E. R. & Daughtry, C. S. T. (2018). What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *International Journal of Remote Sensing*, (39), 5345–5376. <https://doi.org/10.1080/01431161.2017.1410300>
- Jacobsen, A., Broge, N. H. & Hansen, B. U. (1995). Monitoring wheat fields and grasslands using spectral reflectance data. Gehalten auf der International Symposium on Spectral Sensing Research (ISSSR), Melbourne, Australia.
- Jucker, P. & Werder, C. (2015). Verbuschung und Problempflanzen im Sömmerungsgebiet: Leitfaden für Kontrollierende. AGRIDEA.
- Komárek, J., Klouček, T. & Prošek, J. (2018). The potential of Unmanned Aerial Systems: A tool towards precision classification of hard-to-distinguish vegetation types? *International Journal of Applied Earth Observation and Geoinformation*, (71), 9–19.
<https://doi.org/10.1016/j.jag.2018.05.003>
- Laliberte, A. S., Goforth, M. A., Steele, C. M. & Rango, A. (2011). Multispectral Remote Sensing from Unmanned Aircraft: Image Processing Workflows and Applications for Rangeland Environments. *Remote Sensing*, (3), 2529–2551.
<https://doi.org/10.3390/rs3112529>
- Lauber, K., Wagner, G., Gygax, A., Eggenberg, S., Bornand, C., Juillerat, P. et al. (2018). *Flora Helvetica* (Sechste, vollständig überarbeitete Auflage.). Bern: Haupt Verlag.
- Lauber, S., Herzog, F., Seidl, I., Böni, R., Bürgi, M., Gmür, P. et al. (2013). *Zukunft der Schweizer Alpwirtschaft. Fakten, Analysen und Denkanstösse aus dem Forschungsprogramm AlpFUTUR*. Birmensdorf: Eidg. Forschungsanstalt WSL; Zürich-Reckenholz, Forschungsanstalt Agroscope Reckenholz-Tänikon.
- Lauber, S., Schüpbach, B. & Koch, B. (2017). Artenvielfalt im Sömmerungsgebiet. *HOT-SPOT*, (27), 14–16.

- Li, M., Zang, S., Zhang, B., Li, S. & Wu, C. (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatiocontextual Information. *European Journal of Remote Sensing*, 47(1), 389–411. <https://doi.org/10.5721/EuJRS20144723>
- Lopatin, J., Fassnacht, F. E., Kattenborn, T. & Schmidtlein, S. (2017). Mapping plant species in mixed grassland communities using close range imaging spectroscopy. *Remote Sensing of Environment*, 201, 12–23. <https://doi.org/10.1016/j.rse.2017.08.031>
- OECD Umweltprüfbericht Schweiz 2017 (Kurzfassung). (2017). Bern: Bundesamt für Umwelt. Verfügbar unter: <https://www.bafu.admin.ch>
- Pix4Dmapper. (2019). Prilly: Pix4D S.A.
- Psomas, A., Zimmermann, N. E., Kneubühler, M., Kellenberger, T. & Itten, K. (2005). Seasonal variability in spectral reflectance for discriminating grasslands along a dry-mesic gradient in Switzerland. Gehalten auf der 4th EARSeL Workshop on Imaging Spectroscopy. <https://doi.org/10.5167/uzh-97041>
- senseFly eBee plus. Herstellerbroschüre. (2018). senseFly Parrot Group.
- senseFly Parrot Group. (2019). senseFly. Camera Collection. Ein professioneller Sensor für jede Anwendung.
- theandroidseb. (2019). Map Marker.
- Tomašík, J., Mokroš, M., Surový, P., Grznárová, A. & Merganič, J. (2019). UAV RTK/PPK Method—An Optimal Solution for Mapping Inaccessible Forested Areas? *Remote Sensing*, 11(721), 19. <https://doi.org/10.3390/rs11060721>
- Torres-Sánchez, J., López-Granados, F. & Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, (115), 43–52. <https://doi.org/http://dx.doi.org/10.1016/j.compag.2015.03.019>
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I. & López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, (103), 104–113.
- Verordnung über die Direktzahlungen an die Landwirtschaft (DZV). (23. Oktober 2013). SR 910.13 (Stand: 1. Januar 2019).
- Viljanen, N., Honkavaara, E., Näsi, R., Hakala, T., Niemeläinen, O. & Kaivosoja, J. (2018). A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* 2018, 8, 28. <https://doi.org/10.3390/agriculture8050070>
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K. & Mortensen, D. A. (1995). Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions. *Transactions of the ASABE*. <https://doi.org/10.13031/2013.27838>
- Zhang, X., Wu, S., Yan, X. & Chen, Z. (2016). A global classification of vegetation based on NDVI, rainfall and temperature. *International Journal of Climatology*. <https://doi.org/10.1002/joc.4847>

6 Abbildungsverzeichnis

Abb. 1: Das Untersuchungsgebiet 'Alp Muotselfvas im Schweizer Oberengadin. In Rot sind die BFF Grenzen dargestellt. Gelb stellt den Weidezaun dar. Beide stammen aus den BFF-Erhebungsdaten 2017 von K. Edelkraut (ZHAW).....	9
Abb. 2: Schematische Übersicht über den Arbeitsablauf (schwarz). In grün sind die groben Prozessschritte dargestellt und in blau die dafür verwendeten Computerprogramme. Zur Darstellung der Ergebnisse 'produktives Weideland' wird zusätzlich Microsoft Excel verwendet.....	10
Abb. 3: Die Drohne senseFly eBee pluss und ihre Flugroute mit der Parrot Sequoia +. Geflogen wurde hangparallel von oben nach unten.	12
Abb. 4: Orthomosaik der Alp Muotselfvas mit den auf das Untersuchungsgebiet angepassten BFF-Grenzen (rot), dem Weidezaun (orange) sowie den aus der terrestrischen Begehung (09.07.2019) erfassten Referenzpunkten (blau) und Vegetationsaufnahmen (Sterne gelb). .	14
Abb. 5: Schematische Unterteilung der einzelnen Klassen.....	15
Abb. 6: Beispiel einer nährstoffreichen Mulden-Vegetation, Alp Muotselfvas.....	16
Abb. 7: 3D-Rekonstruktion des Untersuchungsgebiets Alp Muotselfvas. Rechts zeigt die Ansicht aus Südosten und links aus Nordosten.....	17
Abb. 8: Darstellung der zwei Vegetationsindizes ExG (rechts) und NDVI (links). Rote Bereiche sind vegetationslose und grün sind Flächen mit Vegetation.....	19
Abb. 9: Beispiel einer Segmentierung (rechts) von Zwergsträuchern des RGB-Orthomosaiks (links).	20
Abb. 10: Beispiele verschiedener Layer Ausschnitte: 1. Orthomosaik, 2. Segmentiertes Bild, 3. Höhenmodell, 4. Klassifikation.....	22
Abb. 11: Beispiel eines ursprünglichen Trainingsgebiet (hellblau) aus der Klasse offener Boden der multispektralen Reflektionskarte, welches verschoben werden musste, damit es wieder auf dem Weg anstatt auf der Wiese liegt.	23
Abb. 12: Rechts zeigt im Vordergrund eine Kuppe mit alpiner Windheide, worauf eine Mulde und eine erneute Kuppe, welche von Zwergsträuchern besetzt ist. Links zeigt die gleiche Stelle als Klassifikation von oben. Die Farblegende befindet sich auf der klassierten Lebensraumkarte Abb. 13.	25
Abb. 13: Lebensraumkarte generiert aus der überwachten objektbasierten Bildklassifizierung (OBIA).	26

Abb. 14: Der Polygon-Layer wurde über das Orthomosaik gelegt, um zu überprüfen, wie gut die Lebesraumeinteilung der Klassifikation erfolgte.	28
Abb. 15: Zum Vergleich der gezogenen Grenzen wurde über die Abbildung 13, die Lebensraumgrenzen von 2017 darübergerlegt. Auffällig ist, dass die neuen teilweise kleiner sind.	29
Abb. 16: Als Vergleich wurde der Polygon-Layer des RGB Datensatzes über die Bildklassifizierung des multispektralen Datensatz gelegt. Die Grenzen stimmen teilweise nicht überein. Krummholzgebüsch und andere Klassen wurden deutlich überklassifiziert.....	31
Abb. 17: Übersicht der ausgeschnittenen BFF-Teilflächen. Die Fläche eins und sechs stellen keine BFF-Qualitätsflächen dar.	32
Abb. 18: Darstellung der prozentualen Verteilung der produktiven, unproduktiven und extrahierten Flächen aus dem RGB Datensatz. In den Balken ist zudem die Fläche in ha angegeben.	33
Abb. 19: Darstellung der prozentualen Verteilung der 'produktiven', 'unproduktiven' und 'extrahierten Flächen aus dem MS Datensatz. In den Balken ist zudem die Fläche in ha angegeben.	34
Abb. 20: Unterschied der Klassifikationsergebnisse des multispektralen Datensatzes bei Erhöhung der minimalen Segmentgrösse 10 (links) auf 20 (rechts). Alpenrosen und andere Zwergsträucher werden deutlich weniger überklassifiziert.	36
Abb. 21: Die Klassifikationsergebnisse der RGB- und multispektralen Daten werden hier anhand von vier Beispielen verglichen. (e) stellt ein unglaublich gutes Abbild von (a) dar. In (f) ist die Falschklassifikation von Alpenrosen und die Minderklassifikation von Lägerstellen ersichtlich. (g) zeigt die Entnahme von Vegetationsschichten und in (h) ist die heterogene Verteilung in strukturreichem Gelände ersichtlich. Die multispektralen Daten zeigen ein weniger genaues Abbild des Orthomosaiks.....	38
Abb. 22: Ein Beispielbild aus dem Untersuchungsgebiet mit einem monotonen Rasenschmielen Bestand.....	41

7 Tabellenverzeichnis

Tab. 1: Eigenschaften der verwendeten senseFly Kameratypen S.O.D.A. und Parrot Sequoia +	11
Tab. 2: Zusammenfassung der wichtigsten Flugparameter der beiden Befliegungen am 07.08.2019 über Alp Muotse-vas, Val Fex, Oberengadin, Schweiz.....	13
Tab. 3: Die Vegetation wurde aufgrund pflanzensoziologischer Stratifikation und ihrer durchschnittlichen Höhe zur gegebenen Wachstumsphase in verschiedene Schichten isoliert. Die Resultate wurden mit dem RGB Orthomosaik verglichen und auf Richtigkeit überprüft. .	18
Tab. 4: Konfusionsmatrix der RGB-Klassifikation ergibt einen Kappa-Übereinstimmungsindex und eine Gesamtgenauigkeit zwischen der klassifizierten Karte und dem Orthomosaik an. .	27
Tab. 5 und 6: Gegenüberstellung der 2017 erfassten Qualitätsanteile und den RGB-Ergebnissen aus 2019. Fläche eins und sechs haben keine BFF-Qualität und zeigen deshalb oben 0%. Ein direkter Vergleich ist aufgrund verschiedener Methoden nicht möglich.....	40

Anhang

- A Aufgabenstellung
- B Plagiatserklärung
- C GIS Methode ausführlich
- D Quality Reports aus Pix4D
- E Vegetationsaufnahmen
- F Kursbericht

Anhang A Aufgabenstellung

Bachelor Arbeit		
Studiengang	UI16	
Titel:	Einsatz von Drohnen zur Beurteilung von Lebensräumen auf der Alp Muot-selvas	
Vertraulich	Nein	
Fachgebiet	Umweltplanung, Naturmanagement	
Namen	Studentin	Monja Salvisberg Gwattstrasse 65 3645 Thun 0799434248 salvimon@students.zhaw.ch
	Korrektorin 1:	Kirsten Edelkraut Schloss, Wädenswil Tel: +41 (0) 58 934 57 96 kirsten.edelkraut@zhaw.ch
	Korrektor 2	Johann Junghardt Grüental, Wädenswil Tel: +41 (0) 58 934 50 13 E-Mail: johann.junghardt@zhaw.ch

<p>Aufgabenstellung</p> <ul style="list-style-type: none"> • Ausgangslage • Zielsetzung • Zusätzliche Auftrags-modalitäten 	<p>Ausgangslage:</p> <p>Bei entsprechender Grösse und Qualität werden artenreiche Grün- und Streuflächen, sogenannte Biodiversitätsförderflächen (BFF) im Sömmerungsgebiet gemäss Direktzahlungsverordnung mit Beiträgen des Bundes entlohnt. Angemeldete Flächen dürfen während der folgenden 8 Jahren nicht an Grösse und Qualität verlieren. Demzufolge werden die Flächen nach einer gewissen Zeit kontrolliert. Die Erstaufnahme und die Erfolgskontrolle erfolgen fast ausschliesslich über Begehungen im Feld, was bei grossen Alpen schnell mehrere Wochen dauern kann.</p> <p>Umweltdaten und Zustandsinformationen müssen heute immer aktueller und genauer zur Verfügung stehen. Drohnen bieten ein neues technologisches Hilfsmittel zur Erfassung von hochaufgelösten Luftbildern. Mit anschliessender Bildklassifikation werden wertvolle Daten im Bereich Umweltmonitoring oder Präzisionslandwirtschaft gewonnen. Im Rahmen dieser Bachelor-Arbeit soll anhand eines konkreten Beispiels getestet werden, ob sich die Analyse von Luftbildern auch zur vereinfachten Aufnahme bzw. Beurteilung von BFF Qualitätsflächenanteilen eignet. Im Weiteren stellt sich die Frage, ob die vorkommenden Lebensräume anhand eines bestimmten Farbspektrums identifizierbar sind.</p> <p>Zielsetzung:</p> <p>Für die Beantwortung der Fragestellung werden ausgewählte Biodiversitätsförderflächen und deren Lebensräume der Alp Muotselvas im Bündner Fex Tal untersucht.</p> <p><u>Forschungsfragen:</u></p> <ol style="list-style-type: none"> 1) Wie weit lassen sich die erhobenen Luftbilddaten mit der angewandten Bildklassifizierung in Lebensräume einteilen? 2) Wie viel Fläche des Untersuchungsgebiet ist produktives Weideland (= mit einem Futterwert) gemäss W. Dietl (1981)*? 3) Welche Lebensräume des Untersuchungsgebiets können anhand eines spezifischen Farbspektrums zuverlässig identifiziert werden? <p>*W. Dietl, P. Berger & M. Ofner, 1981, Die Kartierung des Pflanzenstandortes und der futterbaulichen Nutzungseignung von Naturwiesen, FAP + AGFF, Zürich Reckenholz</p> <p>Zusätzliche Auftragsmodalitäten:</p> <p>Erwartete Resultate</p> <ul style="list-style-type: none"> • Bachelorarbeit nach Weisung gemäss ZHAW • Präsentation und Verteidigung • Kursbericht für eine Zeitschrift
--	--

	<u>Provisorisches Inhaltsverzeichnis:</u> Zusammenfassung Abstract Inhaltsverzeichnis 1 Einleitung 1.1 Ausgangslage 1.2 Fragestellung 2 Material und Methoden 2.1 Untersuchungsgebiet 2.2 Vorbereitung zur Datenerfassung 2.3 Terrestrische Begehung 2.4 Datenauswertung 2.4.1 Luftbildphotogrammetrie 2.4.2 Einteilung in Lebensräume 2.4.3 Ermittlung produktiver Weidefläche 2.4.4 Lebensraum spezifisches Farbspektrum 3 Resultate 3.1 Einteilung in Lebensräume 3.2 Ermittlung produktiver Weidefläche 3.3 Lebensraum spezifisches Farbspektrum 4 Diskussion 4.1 Ermittlung von produktiven Qualitätsflächenanteilen 4.2 Lebensraumeinteilung mit Bildklassifizierung 4.3 Lebensraum spezifisches Farbspektrum 5 Literaturverzeichnis Abbildungs- und Tabellenverzeichnis Anhang (Kursbericht)
Formale Anforderungen:	Die Weisungen zur Arbeit müssen gelesen und erfüllt werden. http://www.lsfm.zhaw.ch/science/studium/info/bachelorstudium/wichtige-dokumente.html
Zeitplan	siehe Anhang Abgabedatum: 24.10.19
Bemerkungen	Abgabeform: Arbeit: elektronisch
Arbeitsort	ZHAW Wädenswil

Plagiate verstossen gegen die Urheberrechte, eine Verletzung dieser Rechte wird gemäss der Studien- und Prüfungsordnung für die Bachelorstudiengänge der Hochschule Wädenswil vom 01.09.2006 in § 38, 39 geregelt. Diese Studien- und Prüfungsordnung gilt für alle Bachelorstudienjahrgänge bis und mit Studienstart 2009.

Für Bachelorstudienjahrgänge mit Studienbeginn ab 2010 und die Masterstudiengänge mit Studienbeginn ab 2009 gilt § 39 der Rahmenprüfungsordnung für Bachelor- und Masterstudiengänge an der Zürcher Hochschule für Angewandte Wissenschaften vom 29.01.2008.

[illegible]

Anhang B Plagiatserklärung

Erklärung betreffend das selbständige Verfassen einer Bachelorarbeit im Departement Life Sciences und Facility Management

Mit der Abgabe dieser Bachelorarbeit versichert der/die Studierende, dass er/sie die Arbeit selbständig und ohne fremde Hilfe verfasst hat.

Der/die unterzeichnende Studierende erklärt, dass alle verwendeten Quellen (auch Internetseiten) im Text oder Anhang korrekt ausgewiesen sind, d.h. dass die Bachelorarbeit keine Plagiate enthält, also keine Teile, die teilweise oder vollständig aus einem fremden Text oder einer fremden Arbeit unter Vorgabe der eigenen Urheberschaft bzw. ohne Quellenangabe übernommen worden sind.

Bei Verfehlungen aller Art treten Paragraph 39 und Paragraph 40 der Rahmenprüfungsordnung für die Bachelor- und Masterstudiengänge an der Zürcher Hochschule für Angewandte Wissenschaften vom 29. Januar 2008 sowie die Bestimmungen der Disziplinarmassnahmen der Hochschulordnung in Kraft.

Ort, Datum:

Thun, 20. 10. 19

Unterschrift:

M. J. J. J.

Das Original dieses Formulars ist bei der ZHAW-Version aller abgegebenen Bachelorarbeiten im Anhang mit Original-Unterschriften und -Datum (keine Kopie) einzufügen.

Anhang C: GIS Methode ausführlich

Datenvorbereitung:

Multispektrale Daten:

Tool	Vorgang	Bemerkung
Create raster dataset	Leeres Rasterpaket erstellen	Wichtig, gleiche Parameter eingeben, wie die Teilflächen haben
Mosaic	Aus 4 Teilflächen 1 Bild erstellen	Für jedes Band einzeln (rot, grün, rededge, nir)
composite	Layerstapel aus allen Bändern generieren	
Map Algebra	NDVI berechnen	$NDVI = (nir - red) / (nir + red)$ -> als Layer exportieren
Reclassify	Vegetation von nicht Vegetation trennen	Schwellenwert: 0.2 Vegetation = 1 keine Vegetation = 2 -> als Layer exportiere
Extract by Mask	Vegetationslose Stellen aus Layerstapel entfernen	Layer from Selection, damit nur 'keine Vegetation' ausgeschnitten wird

CHM:

Tool	Vorgang	Bemerkung	
Map Algebra	DOM – DTM = CHM		
Reclassify	Vegetationsschichten erstellen	Value	Label
		0 – 0.25	1 Grasland
		0.25 – 0.8	2 Zwergsträucher
		0.8 – 1.5	3 Hochstauden, Kleinst- räucher
		1.5 – 3.5	4 Sträucher
		3.5 - 15	5 Bäume

RGB Daten:

Tool	Vorgang	Bemerkung
Map Algebra	ExG berechnen	$ExG = (2 * g) - r - b$ -> als Layer exportieren
Reclassify	Vegetation von nicht Vegetation trennen	Schwellenwert 0.03 Vegetation = 1 Keine Vegetation = 2
Extract by Mask	Vegetationslose Stellen aus Layerstapel entfernen	Layer from Selection, damit nur 'keine Vegetation' ausgeschnitten wird

RGB & Multispektral:

Tool	Vorgang	Bemerkung
Clip	Alle Layer auf die gleiche Grösse zuschneiden	Verwende gleiches Polygon für alle künftigen Ausschnitte (Export .shp)
Editor: Create / Modify	BFF und LRS Layer Grenzen auf Ausschnitt anpassen	

i) Lebensraumeinteilung

RGB Daten

Tool	Vorgang	Bemerkung
Segmentation	Superpixel = Objekte bilden	Spektraldetail: 20 Räumliches Detail: 20 Min. Segmentgrösse: 90
Training Sample Manager	Trainingsgebiete erstellen, verändern	Klassifikationsschema 31 / 41 TS_190911_4055
Preview Classify Classify	SVM-Klassifikator anwenden	Wenn zufrieden klassifizieren, sonst Trainingsgebiete inspizieren und/oder anpassen (inspect trainings samples)
Merge	Klassen zusammenführen	Hier nicht nötig, überspringen
Assign	Falschklassifikationen manuell berichtigen	
Reclass	Reklassifikation	→ thematische Lebensraumkarte
Editor	LRS-Grenzen gemäss Resultat zeichnen	LRS-Grenzen 2017 / 2019 vergleichen Layout zur Datenpräsentation erstellen
Create Accuracy Assessment Points	Erstellt für jede Klasse eine ausgeglichene Anzahl Punkte	Referenzpunkteschema: Equalized Stratified Random
Update Accuracy Assessment Points	Basierend auf dem Orthomosaik manuell die tatsächliche Klasse zuweisen	
Compute Confusion Matrix	Konfusionsmatrix für die Genauigkeitsbeurteilung	Table to Excel für die Datenaufbereitung

Multispektrale Daten:

Tool	Vorgang	Bemerkung
Georeferenzieren	Layer deckungsgleich machen	Orthomosaik und multispektrale Reflektionskarte mit Kontrollpunkten versehen
Segmentation	Superpixel = Objekte bilden	Spektraldetail: 20 Räumliches Detail: 20 Min. Segmentgrösse: 10
Training Sample Manager	Trainingsgebiete erstellen, verändern	Klassifikationsschema 31 / 41 TS_190904_ms Trainingsgebiete kontrollieren, ob wegen tieferer Auflösung noch korrekt
Preview Classify Classify	SVM-Klassifikator anwenden	Wenn zufrieden klassifizieren, sonst Trainingsgebiete inspizieren und/oder anpassen (inspect trainings samples)
Merge	Klassen zusammenführen	Hier nicht nötig, überspringen
Assign	Falschklassifikationen manuell berichtigen	Fläche oberhalb Waldgrenze markieren und Wald alpinen Rasen zuordnen
Reclass	Reklassifikation	→ thematische Lebensraumkarte
Editor	LRS-Grenzen gemäss Resultat zeichnen	LRS-Grenzen 2019 darüberlegen und vergleichen Layout zur Datenpräsentation erstellen

ii) Produktive Weidefläche berechnen

Ab Preview Classify aus i) weiter; für beide Datensätze (RGB, multispektral gleich)

Tool	Vorgang	Bemerkung
Merge	Klassen zusammenführen	Gemäss Klassifikationsschema Klassen den übergeordneten Gruppen produktiv, unproduktiv, extrahiert zuweisen -> Export Raster
Extract by Mask	Jede BFF als Teilfläche ausschneiden	
Raster to polygon	Rasterdaten in Vektordaten umwandeln	Häkchen setzen bei simplify und create multiple features
Merge	produktiv / unproduktiv / extrahiert gruppieren	In Attributtabelle markieren, gruppieren
Editor	Neue Attributfelder erstellen	Name (text), Shape_Area (double), Prozent (double)
Editor	Feldwerte berechnen	Flächengrösse (Calculate Geometry) Prozentanteile (produktiv / unproduktiv / extrahiert -> Calculate field)
Table to Excel	Attributtabelle in Excel exportieren	Datenaufbereiten, Grafik erstellen
Merge	Alle BFF wieder zusammenfügen	Flächengrössen überprüfen

iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

Tool	Vorgang	Bemerkung
Create spectral profile	Spektralprofil einer Klasse erstellen	Rechtsklick auf Segmentiertem Bild, Trainingsgebiete laden, Klassen selektieren -> kein Resultat

Anhang D Quality Reports aus Pix4D

Quality Report



Generated with Pix4Dmapper version 4.4.12



Important: Click on the different icons for:



Help to analyze the results in the Quality Report



Additional information about the sections



Click [here](#) for additional tips to analyze the Quality Report

Summary



Project	20190730_Fex_ms
Processed	2019-07-30 13:54:27
Camera Model Name(s)	Sequoia_4.0_1280x960 (Green), Sequoia_4.0_1280x960 (Red), Sequoia_4.0_1280x960 (Red edge), Sequoia_4.0_1280x960 (NIR)
Rig name(s)	«Sequoia»
Average Ground Sampling Distance (GSD)	16.75 cm / 6.59 in
Area Covered	0.976 km ² / 97.5713 ha / 0.38 sq. mi. / 241.2286 acres
Time for Initial Processing (without report)	41m:26s

Quality Check



Images	median of 10000 keypoints per image	
Dataset	1884 out of 1884 images calibrated (100%), 12 images disabled	
Camera Optimization	0.03% relative difference between initial and optimized internal camera parameters	
Matching	median of 4270.67 matches per calibrated image	
Georeferencing	yes, no 3D GCP	

Preview




Figure 1: Orthomosaic and the corresponding sparse Digital Surface Model (DSM) before densification.

Calibration Details



Number of Calibrated Images	1884 out of 1896
Number of Geolocated Images	1892 out of 1896

Initial Image Positions






Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

Computed Image/GCPs/Manual Tie Points Positions





Uncertainty ellipses 100x magnified

Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane). Red dots indicate disabled or uncalibrated images. Dark green ellipses indicate the absolute position uncertainty of the bundle block adjustment result.

? Absolute camera position and orientation uncertainties



	X[m]	Y[m]	Z[m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.144	0.141	0.197	0.029	0.034	0.020
Sigma	0.026	0.025	0.041	0.003	0.002	0.002

? Overlap




Figure 4: Number of overlapping images computed for each pixel of the orthomosaic. Red and yellow areas indicate low overlap for which poor results may be generated. Green areas indicate an overlap of over 5 images for every pixel. Good quality results will be generated as long as the number of keypoint matches is also sufficient for these areas (see Figure 5 for keypoint matches).

Bundle Block Adjustment Details



Number of 2D Keypoint Observations for Bundle Block Adjustment	2573477
Number of 3D Points for Bundle Block Adjustment	823429
Mean Reprojection Error [pixels]	0.239



? Internal Camera Parameters

Sequoia_4.0_1280x960 (Green). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]



EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.017797	-0.154056	0.000000	1659.04	0.00	0.00	1659.04	650.84	501.14
Optimized Values	0.000000	1.000000	0.011001	-0.148116	0.000000	1663.43	0.00	0.00	1663.43	651.33	501.78
Uncertainties (Sigma)			0.000206	0.000355		0.15	0.00	0.00	0.15	0.04	0.04





? Internal Camera Parameters

Sequoia_4.0_1280x960 (Red). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]



EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.019718	-0.162426	0.000000	1655.39	0.00	0.00	1655.39	609.75	499.10
Optimized Values	0.000000	1.000000	0.008673	-0.148827	0.000000	1660.47	0.00	0.00	1660.47	609.33	503.88
Uncertainties (Sigma)			0.000763	0.001283		0.23	0.00	0.00	0.23	0.13	0.10




Internal Camera Parameters


Sequoia_4.0_1280x960 (Red edge). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]



EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.012153	-0.147836	0.000000	1666.17	0.00	0.00	1666.17	651.93	460.06
Optimized Values	0.000000	1.000000	0.009442	-0.149178	0.000000	1669.29	0.00	0.00	1669.29	650.99	464.76
Uncertainties (Sigma)			0.001010	0.001690		0.29	0.00	0.00	0.29	0.18	0.14





The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model, is color coded between black and white. White indicates that, on average, more than 16 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the re-projection error for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error.


Internal Camera Parameters

Sequoia_4.0_1280x960 (NIR). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]




EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.015352	-0.156177	0.000000	1673.86	0.00	0.00	1673.86	606.43	463.88
Optimized Values	0.000000	1.000000	0.007547	-0.144472	0.000000	1677.15	0.00	0.00	1677.15	605.87	467.79
Uncertainties (Sigma)			0.001270	0.002180		0.34	0.00	0.00	0.34	0.23	0.19



The correlation between camera internal parameters determined by the bundle adjustment. White indicates a full correlation between the parameters, ie. any change in one can be fully compensated by the other. Black indicates that the parameter is completely independent, and is not affected by other parameters.



The number of Automatic Tie Points (ATPs) per pixel, averaged over all images of the camera model, is color coded between black and white. White indicates that, on average, more than 16 ATPs have been extracted at the pixel location. Black indicates that, on average, 0 ATPs have been extracted at the pixel location. Click on the image to see the average direction and magnitude of the re-projection error for each pixel. Note that the vectors are scaled for better visualization. The scale bar indicates the magnitude of 1 pixel error.

Camera Rig «Sequoia» Relatives. Images: 1884



	Transl X[m]	Transl Y[m]	Transl Z[m]	Rot X[degree]	Rot Y[degree]	Rot Z[degree]
Sequoia_4.0_1280x960 (Green)	Reference Camera					
Sequoia_4.0_1280x960 (Red)						
Initial Values	0.000	-0.015	0.000	-0.120	-0.147	-0.042
Optimized values	0.000	-0.015	0.000	-0.212	-0.195	-0.043
Uncertainties (sigma)				0.006	0.007	0.001
Sequoia_4.0_1280x960 (Red edge)						
Initial Values	0.015	0.000	0.000	0.129	-0.212	0.137
Optimized values	0.015	0.000	0.000	0.051	-0.295	0.134
Uncertainties (sigma)				0.008	0.010	0.001
Sequoia_4.0_1280x960 (NIR)						

Initial Values	0.015	-0.015	0.000	-0.268	-0.361	-0.030
Optimized values	0.015	-0.015	0.000	-0.337	-0.424	-0.025
Uncertainties (sigma)				0.011	0.013	0.001

? 2D Keypoints Table



	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	4271
Min	10000	33
Max	10000	6190
Mean	10000	4164

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Green)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	4442
Min	10000	1613
Max	10000	6190
Mean	10000	4402

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	4068
Min	10000	184
Max	10000	6055
Mean	10000	3842

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red edge)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	3313
Min	10000	71
Max	10000	4835
Mean	10000	3242

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (NIR)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	10000	3069
Min	10000	33
Max	10000	5537
Mean	10000	3120

Median / 75% / Maximal Number of Matches Between Camera Models

	Sequoia_4.0_1... (Green)	Sequoia_4.0_128... (Red)	Sequoia_4....(Red edge)	Sequoia_4.0_128...(NIR)
Sequoia_4.0_1280x960 (Green)	43 / 221 / 3259	22 / 95 / 1378	3 / 10 / 320	3 / 9 / 108
Sequoia_4.0_1280x960 (Red)		71 / 697 / 3864	4 / 14 / 87	3 / 9 / 55
Sequoia_4.0_1280x960 (Red edge)			218 / 721 / 3571	41 / 229 / 1463
Sequoia_4.0_1280x960 (NIR)				267 / 953 / 3804

? 3D Points from 2D Keypoint Matches



	Number of 3D Points Observed
In 2 Images	510660

In 3 Images	130182
In 4 Images	64769
In 5 Images	36176
In 6 Images	22966
In 7 Images	15527
In 8 Images	11003
In 9 Images	7907
In 10 Images	6100
In 11 Images	4496
In 12 Images	3308
In 13 Images	2524
In 14 Images	1871
In 15 Images	1405
In 16 Images	1171
In 17 Images	841
In 18 Images	619
In 19 Images	484
In 20 Images	365
In 21 Images	272
In 22 Images	203
In 23 Images	142
In 24 Images	99
In 25 Images	84
In 26 Images	66
In 27 Images	53
In 28 Images	48
In 29 Images	37
In 30 Images	18
In 31 Images	17
In 32 Images	7
In 33 Images	5
In 34 Images	2
In 35 Images	1
In 36 Images	1

2D Keypoint Matches






Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images. Dark green ellipses indicate the relative camera position uncertainty of the bundle block adjustment result.

Relative camera position and orientation uncertainties

	X[m]	Y[m]	Z[m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.033	0.035	0.030	0.015	0.011	0.006
Sigma	0.009	0.009	0.011	0.005	0.003	0.002

Geolocation Details

Absolute Geolocation Variance

Min Error [m]	Max Error [m]	Geolocation Error X[%]	Geolocation Error Y[%]	Geolocation Error Z[%]
-	-13.41	0.00	0.00	0.00
-13.41	-10.73	0.00	0.00	0.00
-10.73	-8.05	0.00	0.00	0.00
-8.05	-5.36	0.00	0.00	0.00
-5.36	-2.68	0.00	0.64	1.49
-2.68	0.00	47.40	52.34	43.42
0.00	2.68	52.60	47.03	55.10
2.68	5.36	0.00	0.00	0.00
5.36	8.05	0.00	0.00	0.00
8.05	10.73	0.00	0.00	0.00
10.73	13.41	0.00	0.00	0.00
13.41	-	0.00	0.00	0.00
Mean [m]		0.012790	-0.011807	-0.014861
Sigma [m]		0.604554	1.140581	1.105979
RMS Error [m]		0.604690	1.140642	1.106079

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

Relative Geolocation Variance



Relative Geolocation Error	Images X[%]	Images Y[%]	Images Z[%]
[-1.00, 1.00]	100.00	100.00	100.00
[-2.00, 2.00]	100.00	100.00	100.00
[-3.00, 3.00]	100.00	100.00	100.00
Mean of Geolocation Accuracy [m]	4.384392	4.384392	5.615009
Sigma of Geolocation Accuracy [m]	0.545926	0.545926	0.652002

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Geolocation Orientational Variance	RMS [degree]
Omega	4.045
Phi	5.047
Kappa	15.119

Geolocation RMS error of the orientation angles given by the difference between the initial and computed image orientation angles.

Initial Processing Details



System Information



Hardware	CPU: Intel(R) Xeon(R) CPU W3565 @ 3.20GHz RAM: 12GB GPU: NVIDIA Quadro 600 (Driver: 8.17.12.5929), RDPDD Chained DD (Driver: unknown), RDP Encoder Mirror Driver (Driver: unknown), RDP Reflector Display Driver (Driver: unknown)
Operating System	Windows 7 Enterprise, 64-bit


Coordinate Systems



Image Coordinate System	WGS 84 (EGM96 Geoid)
Output Coordinate System	WGS 84 / UTM zone 32N (EGM96 Geoid)

Processing Options



Detected Template	 Ag Multispectral
Keypoints Image Scale	Full, Image Scale: 2
Advanced: Matching Image Pairs	Aerial Grid or Corridor
Advanced: Matching Strategy	Use Geometrically Verified Matching: yes
Advanced: Keypoint Extraction	Targeted Number of Keypoints: Custom, Number of Keypoints: 10000
Advanced: Calibration	Calibration Method: Alternative Internal Parameters Optimization: All External Parameters Optimization: All Rematch: Custom, yes
Rig «Sequoia» processing	optimize relative rotation using a subset of secondary cameras

Point Cloud Densification details



Processing Options



Image Scale	multiscale, 1/2 (Half image size, Default)
Point Density	Low (Fast)
Minimum Number of Matches	3
3D Textured Mesh Generation	no
LOD	Generated: no
Advanced: Image Groups	NIR, Red edge, Red, Green
Advanced: Use Processing Area	yes
Advanced: Use Annotations	yes
Time for Point Cloud Densification	09m:48s
Time for Point Cloud Classification	NA
Time for 3D Textured Mesh Generation	NA

Results



Number of Generated Tiles	1
Number of 3D Densified Points	884696
Average Density (per m ³)	0.25

DSM, Orthomosaic and Index Details



Processing Options



DSM and Orthomosaic Resolution	1 x GSD (16.7 [cm/pixel])
DSM Filters	Noise Filtering: yes Surface Smoothing: yes, Type: Sharp
Radiometric calibration with reflectance target	yes
Index Calculator: Reflectance Map	Generated: yes Resolution: 1 x GSD (16.7 [cm/pixel]) Merge Tiles: no
Index Calculator: Indices	ndvi
Index Calculator: Index Values	Polygon Shapefile [cm/grid]: 400
Time for DSM Generation	00s
Time for Orthomosaic Generation	00s
Time for DTM Generation	00s
Time for Contour Lines Generation	00s
Time for Reflectance Map Generation	02h:22m:28s
Time for Index Map Generation	53s

Camera Radiometric Correction



Camera Name	Band	Radiometric Correction Type	Reflectance target
-------------	------	-----------------------------	--------------------

Sequoia_4.0_1280x960	Green	Camera and Sun Irradiance	✓
Sequoia_4.0_1280x960	Red	Camera and Sun Irradiance	✓
Sequoia_4.0_1280x960	Red edge	Camera and Sun Irradiance	✓
Sequoia_4.0_1280x960	NIR	Camera and Sun Irradiance	n/a

Quality Report



Generated with Pix4Dmapper version 4.4.12



Important: Click on the different icons for:



Help to analyze the results in the Quality Report



Additional information about the sections



Click [here](#) for additional tips to analyze the Quality Report

Summary



Project	Fex_rgb_190812
Processed	2019-08-13 10:02:00
Camera Model Name(s)	S.O.D.A_10.6_5472x3648 (RGB)
Average Ground Sampling Distance (GSD)	4.24 cm / 1.67 in
Area Covered	0.948 km ² / 94.7837 ha / 0.37 sq. mi. / 234.3369 acres
Time for Initial Processing (without report)	41m:48s

Quality Check



Images	median of 78020 keypoints per image	
Dataset	272 out of 275 images calibrated (98%), all images enabled	
Camera Optimization	0.82% relative difference between initial and optimized internal camera parameters	
Matching	median of 25547.1 matches per calibrated image	
Georeferencing	yes, no 3D GCP	

Preview




Figure 1: Orthomosaic and the corresponding sparse Digital Surface Model (DSM) before densification.

Calibration Details



Number of Calibrated Images	272 out of 275
Number of Geolocated Images	275 out of 275

? Initial Image Positions






Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

? Computed Image/GCPs/Manual Tie Points Positions





Uncertainty ellipses 1000x magnified

Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane). Red dots indicate disabled or uncalibrated images. Dark green ellipses indicate the absolute position uncertainty of the bundle block adjustment result.

? Absolute camera position and orientation uncertainties



	X[m]	Y[m]	Z[m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.010	0.011	0.008	0.004	0.004	0.003
Sigma	0.002	0.001	0.002	0.001	0.001	0.001

? Overlap




Figure 4: Number of overlapping images computed for each pixel of the orthomosaic. Red and yellow areas indicate low overlap for which poor results may be generated. Green areas indicate an overlap of over 5 images for every pixel. Good quality results will be generated as long as the number of keypoint matches is also sufficient for these areas (see Figure 5 for keypoint matches).

Bundle Block Adjustment Details





Number of 2D Keypoint Observations for Bundle Block Adjustment	6800772
Number of 3D Points for Bundle Block Adjustment	2655344
Mean Reprojection Error [pixels]	0.216

Internal Camera Parameters

S.O.D.A._10.6_5472x3648 (RGB). Sensor Dimensions: 13.133 [mm] x 8.755 [mm]

EXIF ID: S.O.D.A._10.6_5472x3648

	Focal Length	Principal Point x	Principal Point y	R1	R2	R3	T1	T2
Initial Values	4430.420 [pixel] 10.633 [mm]	2725.000 [pixel] 6.540 [mm]	1811.670 [pixel] 4.348 [mm]	0.033	-0.209	0.315	0.000	0.000
Optimized Values	4393.794 [pixel] 10.545 [mm]	2755.290 [pixel] 6.613 [mm]	1782.174 [pixel] 4.277 [mm]	0.026	-0.190	0.284	-0.004	0.001
Uncertainties (Sigma)	0.154 [pixel] 0.000 [mm]	0.099 [pixel] 0.000 [mm]	0.092 [pixel] 0.000 [mm]	0.000	0.001	0.001	0.000	0.000



2D Keypoints Table

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	78020	25547
Mn	69519	2324
Max	85683	37914
Mean	78017	25003

3D Points from 2D Keypoint Matches

	Number of 3D Points Observed
In 2 Images	1886454
In 3 Images	430100
In 4 Images	164302
In 5 Images	79588
In 6 Images	42392
In 7 Images	23460
In 8 Images	13157
In 9 Images	7553

In 10 Images	4251
In 11 Images	2179
In 12 Images	1079
In 13 Images	524
In 14 Images	220
In 15 Images	70
In 16 Images	13
In 17 Images	2

? 2D Keypoint Matches




Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images. Dark green ellipses indicate the relative camera position uncertainty of the bundle block adjustment result.

? Relative camera position and orientation uncertainties



	X[m]	Y[m]	Z[m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.020	0.022	0.019	0.009	0.007	0.004

Sigma	0.006	0.006	0.008	0.003	0.002	0.001
-------	-------	-------	-------	-------	-------	-------

Geolocation Details

Absolute Geolocation Variance

Mn Error [m]	Max Error [m]	Geolocation Error X[%]	Geolocation Error Y[%]	Geolocation Error Z[%]
-	-0.12	0.00	0.00	0.00
-0.12	-0.10	0.00	0.00	0.00
-0.10	-0.07	0.37	0.37	0.37
-0.07	-0.05	0.74	3.68	1.84
-0.05	-0.02	8.09	12.50	12.13
-0.02	-0.00	38.24	33.09	33.82
-0.00	0.02	43.38	36.03	38.60
0.02	0.05	8.82	11.40	12.87
0.05	0.07	0.37	2.57	0.37
0.07	0.10	0.00	0.37	0.00
0.10	0.12	0.00	0.00	0.00
0.12	-	0.00	0.00	0.00
Mean [m]		0.000084	-0.000421	-0.000357
Sigma [m]		0.019177	0.024578	0.021906
RMS Error [m]		0.019177	0.024581	0.021908

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

Relative Geolocation Variance

Relative Geolocation Error	Images X[%]	Images Y[%]	Images Z[%]
[-1.00, 1.00]	94.12	86.76	96.69
[-2.00, 2.00]	100.00	99.63	100.00
[-3.00, 3.00]	100.00	100.00	100.00
Mean of Geolocation Accuracy [m]	0.036352	0.036352	0.047153
Sigma of Geolocation Accuracy [m]	0.004153	0.004153	0.006008

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Geolocation Orientational Variance	RMS [degree]
Omega	5.505
Phi	6.132
Kappa	12.820

Geolocation RMS error of the orientation angles given by the difference between the initial and computed image orientation angles.

Initial Processing Details

System Information

Hardware	CPU: Intel(R) Core(TM) i7-8550U CPU @ 1.80GHz RAM: 8GB GPU: Intel(R) UHD Graphics 620 (Driver: 25.20.100.6373)
----------	--

Operating System	Windows 10 Pro, 64-bit
------------------	------------------------

Coordinate Systems



Image Coordinate System	WGS 84
Output Coordinate System	WGS 84 / UTMzone 32N

Processing Options



Detected Template	No Template Available
Keypoints Image Scale	Full, Image Scale: 1
Advanced: Matching Image Pairs	Aerial Grid or Corridor
Advanced: Matching Strategy	Use Geometrically Verified Matching: yes
Advanced: Keypoint Extraction	Targeted Number of Keypoints: Automatic
Advanced: Calibration	Calibration Method: Alternative Internal Parameters Optimization: All External Parameters Optimization: All Rematch: Auto, yes

Point Cloud Densification details



Processing Options



Image Scale	multiscale, 1/2 (Half image size, Default)
Point Density	Optimal
Minimum Number of Matches	3
3D Textured Mesh Generation	yes
3D Textured Mesh Settings:	Resolution: High Resolution Color Balancing: yes
LOD	Generated: no
Advanced: 3D Textured Mesh Settings	Sample Density Divider: 1
Advanced: Image Groups	group1
Advanced: Use Processing Area	yes
Advanced: Use Annotations	yes
Time for Point Cloud Densification	01h:25m:13s
Time for Point Cloud Classification	21m:58s
Time for 3D Textured Mesh Generation	02h:19m:37s

Results



Number of Processed Clusters	6
Number of Generated Tiles	3
Number of 3D Densified Points	39945896
Average Density (per m ³)	36.28

DSM, Orthomosaic and Index Details



Processing Options



DSM and Orthomosaic Resolution	1 x GSD (4.24 [cm/pixel])
DSM Filters	Noise Filtering: yes Surface Smoothing: yes, Type: Sharp
Raster DSM	Generated: yes Method: Inverse Distance Weighting Merge Tiles: yes

Orthomosaic	Generated: yes Merge Tiles: yes GeoTIFF Without Transparency: yes Google Maps Tiles and KML: yes
Grid DSM	Generated: yes, Spacing [cm]: 100
Raster DTM	Generated: yes Merge Tiles: yes
DTMResolution	5 x GSD (4.24 [cm/pixel])
Contour Lines Generation	Generated: yes Contour Base [m]: 0 Elevation Interval [m]: 10 Resolution [cm]: 100 Minimum Line Size [vertices]: 20
Time for DSM Generation	01h:13m:03s
Time for Orthomosaic Generation	01h:48m:09s
Time for DTM Generation	35m:38s
Time for Contour Lines Generation	04s
Time for Reflectance Map Generation	00s
Time for Index Map Generation	00s

Anhang E Vegetationsaufnahmen

Vegetationsaufnahme Kopfdaten:

1

Datum: P1 Bearbeiter_innen: _____ ID Aufnahme: _____

Ort: _____

Uhrzeit Aufnahme Beginn: _____ Plotform: _____ Plotfläche: _____ Deckung Vegetation: _____

Uhrzeit Aufnahme Ende: _____ Plotzentrumkoordinaten: _____

Wetter: Regen ja/nein: _____ X: _____ / _____ ± m

Neigung: Exposition: Z: _____ / _____ ± m

Lebensraumeinheit gutachterisch: _____ % Deckung: _____

1: _____ 2: _____ 3: _____

Deckung Vegetation:

Flechten	
Moose	
Krautpflanzen	85
Zwergsträucher	
Straucher	
Bäume	

Boden:

Offene Wasserfläche	
Steine/Fels	
Offener Sand	
Offener Kien	
Offene Erde	
Streu	
Totholz	

Weitere Umweltfaktoren / Bemerkungen / Skizze / etc.

Leontodon

Lotus

tr. alp.

PA Nardion

p2 wüchsig, nährstoffreicher,

LRS UNR: Nardion

Dietl: Poion alpina
44 (45)

→ BFF Indikatorpfl.

Vegetationsaufnahme Arten:

Deckungscode nach Braun-Blanquet

1 = selten (<1%) 2 = wenig (>1%) 3 = 1-5% 4 = 5-25% 5 = 25-50% 6 = 50-75% 7 = 75-100%

K = Krautflora S = Strauchflora B = Baumflora

ID Aufnahme: _____ Deckungscode: _____

Arten in der Aufnahme:

- + Potentilla aurea
- + Geum montanum
- + Leontodon hispidus
- + Lotus alpinus
- + Leontodon helveticus
- + Ranunculus montanus
- + Alnus montana
- + Thesium alpinum
- + Alchemilla sp.
- + Cirsium sp.
- + Myosotis alpestris
- + Trifolium alpinum
- + Trifolium nivalis
- + Polygonum viviparum
- + Galium pumilum
- + Plantago alpina
- + Erigeron uniflorus
- + Leucanthemopsis alpina
- + Deschampsia cesp.
- + Nardus stricta
- + Poa alpina
- + Anthoxanthum alpinum
- + Poa laxa
- + Veronica alpina
- + H. hopeanum
- + Phytolacca hirsutissima
- + Geranium hirsutum
- + Phytolacca hirsutum
- + Achillea millefolium

Bemerkungen

Deckung

K S B

LR Code

Kreuztabelle «Bottom up»
(vgl. S.22 & 23)

Anzahl Arten

Summe Punkte

31

Vegetationsaufnahme Kopfdaten:

2

Datum: P7 Bearbeiter_innen: _____ ID Aufnahme: _____

Ort: _____

Uhrzeit Aufnahme Beginn: _____ Plotform: _____ Plotfläche: _____ Deckung Vegetation: _____

Uhrzeit Aufnahme Ende: _____ Plotzentrumkoordinaten: _____

Wetter: Regen ja/nein: _____ X: _____ / _____ ± m

Neigung: Exposition: Z: _____ / _____ ± m

Lebensraumeinheit gutachterisch: _____ % Deckung: _____

1: _____ 2: _____ 3: _____

Deckung Vegetation:

Flechten	
Moose	
Krautpflanzen	
Zwergsträucher	
Straucher	
Bäume	

Boden:

Offene Wasserfläche	
Steine/Fels	
Offener Sand	
Offener Kien	
Offene Erde	
Streu	
Totholz	

Weitere Umweltfaktoren / Bemerkungen / Skizze / etc.

Nardion (Caricion curvulae)

Dietl: 64, 67 → 64x67
(64Va1 x 67)
(64Va2 x 67)
64Lo2 x 67

Vegetationsaufnahme Arten:

Deckungscode nach Braun-Blanquet

1 = selten (<1%) 2 = wenig (>1%) 3 = 1-5% 4 = 5-25% 5 = 25-50% 6 = 50-75% 7 = 75-100%

K = Krautflora S = Strauchflora B = Baumflora

ID Aufnahme: _____ Deckungscode: _____

Arten in der Aufnahme:

- + Potentilla aurea
- + Leontodon helveticus
- + Potentilla apifolia
- + Hieracium hopeanum
- + Trifolium alpinum
- + Veronica alpina
- + Carex curvula
- + Antennaria dioica
- + Loiseleuria procumbens
- + Polygonum viviparum
- + Hieracium villosum
- + Luzula lutea
- + Elyna myo...
- + Leucanthemopsis
- + Luzula alpina
- + Hieracium villosum
- + Festuca halleri
- + Poa alpina
- + Vaccinium myrtillus

Bemerkungen

Deckung

K S B

LR Code

Kreuztabelle «Bottom up»
(vgl. S.22 & 23)

Anzahl Arten

Summe Punkte

31

Vegetationsaufnahme Kopdaten:

3

Datum: _____ Bearbeiter_innen: _____
 Ort: P12 ID Aufnahme: _____

Uhrzeit Aufnahme Beginn: _____ Plotform: _____ Plotfläche: _____ m²
 Uhrzeit Aufnahme Ende: _____ Plotzentrumkoordinaten: _____
 Wetter: Regen ja/nein: _____ X: _____ / _____ ± m
 Y: _____ / _____ ± m
 Neigung: _____ Exposition: _____ Z: _____ / _____ ± m

Lebensraumeinheit gutachterlich: _____ % Deckung: _____

Weitere Umweltfaktoren / Bemerkungen / Skizze / etc.

Deckung Vegetation:

Flechten	
Moose	
Krautpflanzen	
Zwergsträucher	
Straucher	
Bäume	

Boden:

Offene Wasserfläche	
Steine/Fels	
Offener Sand	
Offener Klee	
Offene Erde	
Streu	
Totholz	

URS UNR: Nardion
 Dietl: Nardion
 64 x 68
 64 Va2
 64 Va3

Vegetationsaufnahme Arten:

Deckungscode nach Braun-Blanquet: 1 = selten (<5%), 2 = wenig (5-15%), 3 = 15-30%, 4 = 30-50%, 5 = 50-75%, 6 = 75-100%
 K = Krautschicht, K = Krautflanke oder < 0,5 m S = Strauchschicht = Gehölz und 0,5-4 m
 B = Baumschicht = Gehölz und > 4 m
 ID Aufnahme: _____ Deckungscode: _____

Arten in der Aufnahmefläche

	Deckung			LRF-Code
	K	S	B	
+ Arnica montana				
+ Nardus stricta				
+ Potentilla aurea				
+ Leontodon helveticus				
+ Geum montanum				
- Platanthera bifolia				
- Homogyne alpina				
- Luzula lutea				
- Leucanthemopsis				
+ Trifolium alpinum				
- Poa alpina				
- Luzula alpina				
- Carex sp.				
+ Vaccinium myrtillus				
- Juniperus nana				
- Carex curvula				
- Apiaceae				
- Festuca halleri				
- Gelber Enzian				
- Poa laxa				

Bemerkungen: _____

Anzahl Arten: _____
 Summe Punkte: _____

Vegetationsaufnahme Kopdaten:

Datum: _____ Bearbeiter_innen: _____
 Ort: P29 ID Aufnahme: _____

Uhrzeit Aufnahme Beginn: _____ Plotform: _____ Plotfläche: _____ m²
 Uhrzeit Aufnahme Ende: _____ Plotzentrumkoordinaten: _____
 Wetter: Regen ja/nein: _____ X: _____ / _____ ± m
 Y: _____ / _____ ± m
 Neigung: _____ Exposition: _____ Z: _____ / _____ ± m

Lebensraumeinheit gutachterlich: _____ % Deckung: _____

Weitere Umweltfaktoren / Bemerkungen / Skizze / etc.

Deckung Vegetation:

Flechten	
Moose	
Krautpflanzen	
Zwergsträucher	
Straucher	
Bäume	

Boden:

Offene Wasserfläche	
Steine/Fels	
Offener Sand	
Offener Klee	
Offene Erde	
Streu	
Totholz	

Vegetationsaufnahme Arten:

Deckungscode nach Braun-Blanquet: 1 = selten (<5%), 2 = wenig (5-15%), 3 = 15-30%, 4 = 30-50%, 5 = 50-75%, 6 = 75-100%
 K = Krautschicht, K = Krautflanke oder < 0,5 m S = Strauchschicht = Gehölz und 0,5-4 m
 B = Baumschicht = Gehölz und > 4 m
 ID Aufnahme: _____ Deckungscode: _____

Arten in der Aufnahmefläche

	Deckung			LRF-Code
	K	S	B	
+ Carex curvula				
+ Potentilla aurea				
+ Laveleya procumbens				
+ Luzula lutea				
+ Nardus stricta				
+ Trifolium alpinum				
- Arnica montana				
- Leontodon helveticus				
- Leontodon hispidus				
- Poa alpina				
- Vaccinium myrtillus				
- Phleum alpinum				
- Homogyne alpina				
- Leucanthemopsis				
- Luzula alpina				
- Poa laxa				

Bemerkungen: _____

Anzahl Arten: _____
 Summe Punkte: _____

Einsatz von Drohnen zur Beurteilung von Lebensräumen auf der Alp Muotselvas

Monja Salvisberg ^a, Kirsten Edelkraut ^b, Johann Junghardt ^c

^a Bsc Umweltingenieurswesen, Gwattstrasse 65, 3645 Gwatt (Thun), Monja.Salvisberg@gmail.com

^b Forschungsgruppe Umweltplanung, edek@zhaw.ch

^c Forschungsgruppe Geoinformatik, murj@zhaw.ch

Abstract

In order to conserve and promote biodiversity and the swiss natural capital in summering alps, areas with special biological quality are inventoried and regularly inspected. Using the example of the Alp Muotselvas, this work attempts to examine whether drones can be used to delimitate habitats. In addition, the question arises whether these habitats have a specific color spectrum. The study area is located in the Fex valley in the Swiss Upper Engadin between 2100 and 2400 m above sea level. An RGB and a multispectral Sensor were mounted on a Sensefly eBee plus drone. Using the 'Structure from Motion' method from aerial photogrammetry, orthomosaics, elevation models and reflection maps were created in Pix4D. A supervised, object-based image classification using the "Support Vector Machine algorithm" was executed in ArcGIS Pro. The RGB dataset was due to better Sensors more suitable for the creation of a habitat map and the determination of the productive pastureland with fodder value than the multispectral data. Overall, the results were significantly improved by adding the extraction of the elevation model and the vegetation indices (NDVI, ExG). A specific spectral profile of the habitats could not be determined with this method. While the use of drones to record and control the areas with special biological quality is helpful, an initial, detailed field survey remains necessary. Multispectral and hyperspectral sensors are promising tools for studying habitats and the distribution of species. Further drone-based studies are needed.

Keywords: Biodiversitätsförderflächen, Drohnen, RGB, multispektral, Structre from motion (SfM), Objekt-basierte Bildklassifikation (OBIA), Support Vector Machine (SVM), Höhenmodell, NDVI, ExG

1 Einleitung

Sommerungsgebiete sind nicht nur ein Kennzeichen der vielfältigen Schweizer Kulturlandschaft, sie gehören auch zu den artenreichsten Lebensräumen der subalpinen und alpinen Höhenstufen. Durch Rodungen und saisonale Wanderung konnten sich Tier- und Pflanzenarten aus verschiedensten Gebieten etablieren. Das Mikroklima ist durch Standortfaktoren wie Höhe, Hangneigung und Exposition auf kleinstem Raum sehr unterschiedlich und bietet gerade deshalb grosses Potential für Artenvielfalt. In den Nischen mit gleichen Umweltbedingungen stellen sich typische Artkombinationen ein (Lauber Herzog, Seidl, Böni, Bürgi, Gmür, Hofer, Mann, Raaflaub, Schick, Schneider & Wunderli, 2013). Alpine Rasen, Zwergstrauchgesellschaften, Grünerlegebüsche und Arven-/ Lärchenwälder sind auf der Höhenstufe vorherrschend (Delarze, Gonseth, Eggenberg & Vust, 2015; Lauber, Wagner, Gyax, Eggenberg, Bornand, Juillerat, Jutzi, Möhl, Nyffeler & Santiago, 2018).

Rund 17'000 Äpler und Äplerinnen sorgen jährlich mit beinahe 800'000 Tieren für die Offenhaltung artenreicher Flächen und schützen die Täler vor Naturgefahren (Lauber, Schüpbach & Koch, 2017). Wird eine Alp aufgegeben, kommt es schnell zur Verbuschung durch Zwergsträucher, Grünerlen und Bäumen, wird sie zu intensiv genutzt, verarmen Flora und Fauna (Delarze et al., 2015; Lauber et al., 2013). Übernutzung fördert zudem Problempflanzen wie die Alpen-Blake oder das Alpen-Kreuzkraut, welche vom Vieh verschmäht werden und somit den Futterwert der Weidefläche herabsetzen (Jucker & Werder, 2015).

Für den Erhalt und die Förderung von Arten und ihren Lebensräumen legt der Bund im Bundesgesetz über die Landwirtschaft Art. 73 („Bundesverfassung der Schweizerischen

Eidgenossenschaft (BV)“, 2000) fest, dass artenreiche Grün- und Streuflächen im Sommerungsgebiet, welche die Qualitätsstufe II erreichen, mit einem Beitrag pro Hektare subventioniert werden ("Verordnung über die Direktzahlungen an die Landwirtschaft (DZV)", 2013).

Nach Anmeldung dieser Biodiversitätsförderflächen (BFF) ist während einer Verpflichtungsdauer von 8 Jahren der Erhalt in Grösse und Qualität sowie entsprechender Bewirtschaftung eine Bedingung. Zudem müssen Indikatorpflanzen, welche auf einen nährstoffarmen und artenreichen Bestand hinweisen, regelmässig vorkommen (Benz, 2014a; Bundesamt für Landwirtschaft, 2018).

Die Ersterfassung sowie die Kontrolle der BFF wird von Umwelfachleuten in Form von Vegetationsaufnahmen während terrestrischen Begehungen durchgeführt. Gemäss Benz (2014b) werden BFF-Teilflächen aufgrund von Bewirtschaftungseinheiten und gleichmässigem Anteil und Verteilung der Lebensraumtypen und Indikatorpflanzen abgegrenzt. Weil Qualitätsvegetation und Vegetation ohne Qualität oft ein Mosaik bilden, ist es für Fachleute eine grosse Herausforderung klare und nachvollziehbare Grenzen zu ziehen. Weiter wird pro BFF-Qualitätsflächen der Anteil mit unproduktiven Elementen und / oder Vegetation ohne Indikatorpflanzen geschätzt. Jene mit über 10% unproduktivem Flächenanteil erhalten einen Beitragsabzug, der durch den Kanton berechnet wird (Benz, 2014b). Obwohl alle nach der gleichen Methode erfasst werden, bleiben Schätzungen subjektiv. Mit zunehmender Alpgrösse und Schwierigkeit des Geländes steigen indes auch der Zeitaufwand und die Kosten.

Um solche Konflikte der täglichen Planungspraxis zu lösen, kommen in der Umweltbranche seit einiger Zeit Methoden der

Fernerkundung zum Einsatz. Mit ihnen können grössere Gebiete über längere Zeiträume untersucht werden (Durfee, Ochoa & Mata-Gonzalez, 2019). Die gewonnenen Datenpakete werden anschliessend mit geographischen Informationssystemen (GIS) quantitativ und qualitativ analysiert.

Zu den bedeutendsten technologischen Innovationen der letzten zehn Jahre gehören Drohnen (Christen, Guillaume, Jablonowski, Lenhart & Moll, 2018), auch unbemanntes Fluggerät (UAV – unmanned aerial vehicle) oder unbemanntes Flugsystem (UAS - unmanned aerial system) genannt (Baumgärtel & Landrock, 2018). Sie fliegen tiefer als Flugzeuge oder Satelliten und erfassen deshalb hoch aufgelöste Bilddaten mit Pixelgrössen im Zentimeterbereich (Hunt Jr. & Daughtry, 2018; Torres-Sánchez, Peña, de Castro & López-Granados, 2014). Zudem können Drohnen auch bei leicht bewölkter Wetterlage fliegen, sind einfacher zu konfigurieren und nicht auf einen Piloten angewiesen. Die Befliegung kann so, flexibler geplant werden (Torres-Sánchez et al., 2014).

Drohnen werden für Vegetationsanalysen mit RGB (rot, grün, blau) und Multispektralkameras ausgerüstet. RGB Sensoren liefern Bilder aus dem sichtbaren Lichtspektrum, multispektrale nehmen Licht aus dem nah-Infrarot (nir) Bereich auf (Baumgärtel & Landrock, 2018; Komárek, Klouček & Prošek,

2018; Laliberte, Goforth, Steele & Rango, 2011). Da Pflanzen verstärkt Licht im nah-Infrarot Bereich reflektieren, kann mit Hilfe von Vegetationsindizes wie dem NDVI (normalisierter, differenzierter Vegetationsindex) oder dem Excess Green einfacher zwischen vegetationsbedeckten und vegetationslosen Bereichen unterschieden werden (Durfee et al., 2019; Viljanen et al., 2018).

Durch Luftbildphotogrammetrie werden aus Luftbildern Höhenmodelle und Orthomosaik erstellt, welche später im GIS klassifiziert werden und der Erstellung von beispielsweise topographischen Karten dienen (Green, Congalton & Tukman, 2017). Im Umweltbereich finden diese Methoden Anwendung in der Präzisionslandwirtschaft (Baumgärtel & Landrock, 2018; Hunt Jr. & Daughtry, 2018), zur Analyse von Landschaftsstrukturveränderungen oder Vegetationskartierungen (Durfee et al., 2019; Komárek et al., 2018) sowie zur Überwachung von gefährdeten oder invasiven Arten (Babbi, Widmer, Ochsner & Krüsi, 2017).

In der Vergangenheit erfolgte die Bildklassifizierung oft mit pixelbasierten Verfahren. Dank der Entwicklung von neuen sehr hochauflösenden Sensoren liefern Objekt-basierte Verfahren (OBIA, Object-based Image Analysis) bessere Resultate (Blaschke, 2009; Komárek et al., 2018; Laliberte et al., 2011).

OBIA stützt sich auf zwei methodischen Säulen; Segmentation und Klassifikation. Zuerst werden benachbarte Pixel, die Ähnlichkeiten (spektral, räumlich, kontext- und texturbasierend) aufweisen, zu Pixelgruppen zusammengefügt. Anschliessend werden die Gruppen anhand spektraler Eigenschaften klassifiziert (Green et al., 2017; Li, Zang, Zhang, Li & Wu, 2014).

Im Umweltprüfbericht 2017 bemängelte die OECD den Umstand, dass die Schweiz keine Übersicht hat, welche eine räumliche Verteilung der Habitate zeigt (OECD Umweltprüfbericht Schweiz 2017 (Kurzfassung), 2017). So liegt die Vermutung nahe, dass diese Technologien zur Abgrenzung von Lebensräumen im Sömmerungsgebiet eingesetzt werden können. Ein Erfolg würde sowohl den Umweltschleuten zu Gute kommen als auch dem Ziel eine gesamtschweizerische Lebensraumkarte zu erarbeiten.

Im Rahmen dieser Arbeit wird ein Teilgebiet der Alp Fex im Oberengadin mit einer Drohne überflogen. Die Luftbilder werden anschliessend zu Orthomosaiken und Geländemodellen verarbeitet und in einem Geoinformationssystem ausgewertet. Mit den gewonnenen Daten soll geprüft werden, ob die Anwendbarkeit der Methode für die Kartierung und Überwachung von Biodiversitätsförderflächen hilfreich ist: (i) Wie weit lassen sich die erhobenen Luftbilddaten mit der angewandten Bildklassifizierung in Lebensräume einteilen? (ii) Wie viel Fläche des Untersuchungsgebietes ist produktives Weideland, d.h. Weideland mit einem Futterwert gemäss (Dietl, Berger & Ofner, 1981)? (iii) Welche Lebensräume des Untersuchungsgebietes können anhand eines spezifischen Farbspektrums zuverlässig identifiziert werden




Abbildung 1: Schematische Übersicht über den Arbeitsablauf (schwarz). In grün sind die grossen Prozessschritte dargestellt und in blau die dafür verwendeten Computerprogramme. Zur Darstellung der Ergebnisse 'produktives Weideland' wird zusätzlich Microsoft Excel verwendet.

2 Material und Methoden

Das Untersuchungsgebiet ‘Alp Muotselvas’ befindet sich im Val Fex, einem Tal im Oberengadin in den Schweizer Zentralalpen (E = 2°77'938.0 / N= 1°140'593.0). Es handelt sich um einen Ausschnitt von ungefähr 46.5 ha des Sömmerungsgebiets der Alp Muotselvas (Abb. 1). Die Fläche liegt an einem Westhang beginnt oberhalb der Alphütte da Segl auf ungefähr 2100 m.ü.M. und endet auf einer Höhe von 2400 m.ü.M..

Oberhalb von 2000 m.ü.M. sind die klimatischen Verhältnisse fast überall gleich. Es herrscht Gebirgsklima, welches trotz hoher Niederschlagsmengen, durch die tiefen Mitteltemperaturen und häufigen Fröste, eine tiefe Luftfeuchtigkeit aufweist (Baltisberger, Nyffeler & Widmer, 2013). Im Untersuchungsgebiet gibt es nährstoffreiche und magere Weiden sowie verschiedenen Zwergstrauchgesellschaften, Krummholzgebüsche und Nadelhölzer wie Lärchen und Arven (Benz, 2014a; Dietl et al., 1981). Der Arbeitsablauf gliedert sich in Datenerfassung, Datenvorbereitung und Datenverarbeitung. Die Abbildung 1 zeigt einen Gesamtüberblick der einzelnen Arbeitsschritte und den verwendeten Computerprogrammen.




Abb. 2: Die Drohne senseFly eBee plus und ihre Flugroute mit der Parrot Sequoia+. Geflogen wurde hangparallel von oben nach unten.

2.1 Datenerfassung

Drohnenflug

Die Luftbilder wurden mit der Drohne eBee plus von Sensefly (Abb. 2) am 08.07.2019 zwischen 10:00 und 12:00 Uhr aufgenommen. Die Drohne hat mit den abnehmbaren Flügeln eine Spannweite von 110cm und wiegt etwa 1.1kg (je nach verwendeter Kamera). Die verwendeten Kamertypen sind in Tabelle 1 beschrieben. Der multispektrale Sensor der Parrot Sequoia+ nimmt grün, rot, rededge und nir auf. Ihr Sonnenscheinssensor erlaubt absolute Reflexionsmessungen ohne radiometrische Kalibration, der akut wechselnde Strahlungsintensität automatisch ausgleicht. Das drohneneigene GPS/GNSS System nimmt für jede Aufnahme Positionsdaten auf, welche nach dem Flug mit den Bildern georeferenziert werden. In der S.O.D.A.-Kamera ist zudem ein PPK (post processing kinematics) Modul integriert, welches zusätzlich die genauen Lageinformationen der Drohne erfasst, um anschliessend die RGB Bilder mit den Satelliten-Korrekturdaten von swipos (Schweizer Positionierungsdienst des Bundesamts für Landestopografie) bis auf eine Positionsgenauigkeit von 3 cm zu korrigieren („senseFly eBee plus. Herstellerbroschüre.“, 2018).

Tab. 1: Eigenschaften der verwendeten senseFly Kamertypen S.O.D.A. und Parrot Sequoia+.

	senseFly S.O.D.A. 10.6(RGB)	Parrot Sequoia+ 4.0 (nir)
Sensoren	Rot Grün Blau	rot (660nm ± 40nm) grün (550nm ± 40nm) rededge (735nm ± 10nm) nir (790nm ± 40nm)
Kamera Auflösung	20 Megapixel	1.2 Megapixel
Georeferenzierung Bilder	PPK (post processing kinematics)	Geotagging mittels drohneneigenem GPS
Weissabgleich	Automatisch, sonnig, wolkig, schattig	Automatisch
Bildformate	JPEG, DNG+JPEG	JPEG, TIF

Mit dieser Methode bedarf es nicht eines ständigen Funkkontakts der Bodenstation mit der Drohne und Passpunkte (GCP, Ground Control Point) müssen nicht mehr vorgängig im Feld positioniert werden. Die PPK-Methode ist nicht nur genauer, sie ist auch in unzugänglichen oder risikoreichen Gebieten anwendbar, in welchen eine Anbringung von Passpunkten nicht möglich wäre (Tomašík, Mokroš, Surový, Grznárová & Merganic, 2019).

Die Flugplanung wurde in eMotion 3 (eMotion, 2019) geplant. Der Flug erfolgte mit jeder Kamera einmal hangparallel von oben nach unten, was Batterie spart und die potenzielle Flugdauer erhöht (Abb. 2).

Die Flughöhe und -zeit ergaben sich im Allgemeinen nicht nur aus der gewünschten Auflösung, sondern auch aus der Grösse des Untersuchungsgebiets. Bei tieferer Flughöhe ist die Auflösung besser, aber die Datenmengen werden grösser und die Verarbeitung dauert länger. Damit es bei der Konstruktion des Orthomosaiks keine Lücken gibt, wurde eine ausreichend grosse Überlappung gewählt (Tab. 2). Die Wetterkondition waren passend: sonnig und tiefe Windgeschwindigkeiten. Während des zweiten Flugs zogen vereinzelt grössere und dichtere Wolken vorbei und der Wind wurde leicht stärker. Beide Flüge konnten problemlos durchgeführt werden. Die erfassten Flugdaten sind der Tab. 2 zu entnehmen.

Tab. 2: Zusammenfassung der wichtigsten Flugparameter der beiden Befliegungen am 07.08.2019 über Alp Muotselvas, Val Fex, Oberengadin, Schweiz.

	senseFly S.O.D.A. 10.6 (RGB)	Parrot Sequoia+ 4.0 (NIRGB)
Beflogene Fläche (ha)	97.6 ha	97.6 ha
Flughöhe (m)	119m / AED	116.7m /AED
Flugzeit (min)	25 min	28 min
Distanz zwischen Bildern (m)	41m	21m
Gesamtzahl Luftbilder	275	1884
Auflösung (cm/Pixel)	4.24 cm GSD	16.75 cm GSD
Laterale Überlappung (%)	70%	75%
Longitudinale Überlappung (%)	60%	80%
Anzahl kalibrierter Bilder	272 (98%)	1884 (100%)
Durchschnittliche Dichte der Punktwolken pro m³	36.28	0.25

Terrestrische Begehung

Aus der Literatur wurde während der Planung eine Auswahl an mutmasslich vorkommenden Lebensräumen zusammengestellt (Baltisberger et al., 2013; Delarze et al., 2015; Dietl et al., 1981; Lauber et al., 2018). Ein Schnelldurchlauf in Pix4D (Pix4Dmapper, 2019) generierte aus den RGB Luftbildern ein Orthomosaik. Beide Grundlagen begleiteten die Felduntersuchung, welche am 09.07.2019, zwei Tage nach der Befliegung, stattfand.




Abbildung 3: Orthomosaik der Alp Muotselfas mit den auf das Untersuchungsgebiet angepassten BFF-Grenzen (rot), dem Weidezaun (orange) sowie den aus der terrestrischen Begehung (09.07.2019) erfassten Referenzpunkten (blau) und Vegetationsaufnahmen (Sterne gelb).

Die Map Marker-App (theandroidseb, 2019) ermöglichte es, an farblich, strukturell oder botanisch auffälligen Stellen auf der Karte Referenzpunkte zu setzen. Pro Punkt wurden dominante Arten der vorliegenden Vegetationsgesellschaft auf Gattungs- bzw. Art Niveau bestimmt. Grössere farbliche Veränderungen wie beispielsweise die Anhäufung vieler weisser Flechten liessen sich ebenfalls vermerken. Zwei bis drei Fotos pro Referenzpunkt ermöglichten, den Standort nachträglich nochmals in der App anzuschauen. Insgesamt konnten 36 Referenzpunkte gesammelt werden (Abb. 3). Zur Unterscheidung der Weidetypen wurde an drei Standorten mit optisch unterscheidbarer Pflanzenzusammensetzung Vegetationsaufnahmen aufgenommen und nach Dietl et al. (1981) ausgewertet. Zusätzlich diente eine Lebensraumannahme auf lebensraume.unr.ch als Kurzcheck. Die drei Punkte werden später mit den Klassifizierungsergebnissen verglichen.

Die so gewonnenen Daten werden in ein Schema überführt, das es erlaubt die Bilder genauer zu klassifizieren (Abb. 4). Es wird grundsätzlich zwischen vegetationsreich und vegetationslos unterschieden. Zu vegetationslosen Bereichen zählen Steine, Boden und Wasser. Die Vegetation wurde in produktiv und unproduktiv eingeteilt. Alle verholzten Pflanzen wie Zwergsträucher, Krummholzgebüsche und Bäume zählten zu den unproduktiven Elementen und die Weideflächen mit einem Futterwert zu den produktiven Bereichen. Diese umfassten die alpinen Rasen, bestehend aus Borstgrasrasen (*Nardion*) und Krummseggenrasen (*Caricion curvulae*), der Bergfettweide (*Poion alpinae*) und den Lägerstellen (*Rumicion alpinae*). Lägerstellen haben nach der Direktzahlungsverordnung (DZV) keine BFF-Qualität (Hedinger, 2014), Bergfettweiden nur wenn die 6 Indikatorpflanzen vorkommen. Beide weisen gemäss Dietl et al. (1981) einen geringen Futterwert auf und werden in dieser Arbeit deshalb zu den produktiven Flächen gezählt.

In Mulden und an feuchten Stellen sammelten sich nährstoffliebende Stauden wie Alpen-Ampfer (*Rumex alpinus*), Hahnenfuss (*Ranunculus* sp.), Frauenmantel (*Alchemilla* sp.), Rasenschmiele (*Deschampsia cespitosa*), Gewöhnliches Alpen-Lieschgras (*Phleum alpinum*), Läger-Rispengras (*Poa supina*), Alpen-Rispengras (*Poa alpina*), Getüpfelter Enzian (*Gentiana punctata*), Alpen-Kratzdistel (*Cirsium spinosissimum*) und einzelne anderen Arten. Sofern diese in dichten Flecken vorkamen, zählten sie zu den Lägerstellen, sonst zu nährstoffreichen Bereichen. (*Caricion curvulae*), der Bergfettweide (*Poion alpinae*) und den Lägerstellen (*Rumicion alpinae*). Lägerstellen haben nach der Direktzahlungsverordnung (DZV) keine BFF-Qualität (Hedinger, 2014), Bergfettweiden nur wenn die 6 Indikatorpflanzen vorkommen. Beide weisen gemäss Dietl et al. (1981) einen geringen Futterwert auf und werden in dieser Arbeit deshalb zu den produktiven Flächen gezählt.

Eine Unterscheidung zwischen Borstgrasrasen oder Krummseggenrasen konnte auf dem Schnell-Orthomosaik nicht erkannt werden, sie wurden deshalb zu den alpinen Magerrasen zusammengefasst. Alpine Windheiden enthalten zwei verholzte, niederliegende, teppichbildende Spaliersträucher als Charakterarten: die Krähenbeere (*Empetrum nigrum* sp.) und die Gämsheide (*Loiseleuria procumbens*) (Delarze et al., 2015).




Abbildung 4: Schematische Unterteilung der einzelnen Klassen.

Sie wurden zu den Zwergsträuchern gezählt. Die Alpenrosen (*Rhododendron ferrugineum*) waren zum Untersuchungszeitpunkt in roter Blüte, was auf dem schnell generierten Orthomosaik deutlich zu erkennen war. Sie stellen daher eine eigenständige Klasse innerhalb der Zwergsträucher dar.

2.2 Datenvorbereitung

Pix4D

Die photogrammetrische Bildverarbeitung der multispektralen Daten erfolgte mit der Software Pix4Dmapper 4.4.12 (Pix4Dmapper, 2019) in der ZHAW in Wädenswil. Die RGB Bilddaten wurden mit der Testversion Pix4Discovery am eigenen Laptop verarbeitet. Pix4D verwendet eine modifizierte SfM-MVS (Structure from Motion – Multi Stereo View) Methode, um die Bilddaten zu verarbeiten. SfM nutzt Algorithmen, die übereinstimmende Punkte aus sich überlappenden 2D Bildern identifiziert, Kamerapositionen und -orientierung berechnet und daraus 3D Punktwolken generiert. Mit MVS Algorithmen werden die Punktwolken verdichtet und wie in Abb. 5 ersichtlich eine 3D Rekonstruktion des Geländes erstellt (Carrivick, Smith & Quincey, 2016).

In dieser Arbeit wurde aus den RGB Daten ein Orthomosaik (GSD = 4.24 cm/Pixel), ein Digitales Oberflächen Modell (DOM; GSD = 4.24 cm/Pixel) und ein Digitales Terrain Modell (DTM; GSD = 5 * 4.24 cm/Pixel) generiert. Aus den multispektralen Bilddaten wurden pro Band (Lichtkanal) vier Teilstücke erstellt. SfM-MVS Daten mit hoher Auflösung ergeben sehr grosse Datensets, welche die Verarbeitungszeit deutlich verlängern. Trotzdem ist die Datenverarbeitung gemäss Carrivick, Smith, & Quincey (2016) meist kürzer, als wenn alternative Vermessungsmethoden wie beispielsweise Terrestrial Laser Scanning verwendet werden.




Abb. 5: 3D-Rekonstruktion des Untersuchungsgebiets Alp Muotsevas. Rechts zeigt die Ansicht aus Südosten und links aus Nordosten.

ArcGIS Pro

Aus den Mosaikstücken der multispektralen Daten wurde in ArcGIS Pro (Esri Inc., 2019) für jedes Band eine zusammenhängende Reflektionskarte erstellt. Zur Differenzierung der vegetationsreichen und vegetationslosen Bereiche wird der Vegetationsindex NDVI verwendet. Pflanzen reflektieren im Infrarot-Bereich viel mehr Strahlung als im sichtbaren Spektralbereich. Der NDVI nutzt die unterschiedlichen Reflektionsgrade des roten und infraroten Bandes, um die photosynthetische Aktivität von Pflanzen anzuzeigen (Durfee et al., 2019). Sein Wertebereich reicht von -1 bis 1, wobei positive Werte für vegetationsreiche und negative für vegetationslose Bereiche (Zhang, Wu, Yan & Chen, 2016) stehen.

$$NDVI = \frac{nir - red}{nir + red} \quad W_f = \mathbb{R} \setminus \{-1; 1\}$$

Aufgrund einer Überklassifizierung von vegetationslosen Flächen wurde der Schwellenwert auf 0.2 angehoben (Abb. 7). Es folgte eine Reklassifikation des NDVI Layer in Wertebereiche, vegetationslos (< 0.2) und vegetationsreich (> 0.2). Schliesslich wurden die fünf Layer (rot, grün, infrarot, rededge und NDVI) zu einem Paket übereinandergelegt. Sie bildeten das Eingangsprodukt für die überwachte Bildklassifizierung der multispektralen Daten (Abb. 1).

Das Canopy Height Model (CHM), welches die effektive Vegetationshöhe darstellt, berechnete sich durch den Abzug des DTM vom DOM (Green et al., 2017). Für die Berechnung wurden die Pix4D Layer verwendet, da diese aufgrund des gleichen Ursprungs sicher deckungsgleich sind. Eine Reklassifikation des CHM Layers isolierte die Vegetationsschichten. Aufgrund der pflanzensoziologischen Stratifikation erfolgte eine Ersteinteilung, welche anschliessend aufgrund von Durchschnittshöhen häufig vorkommender Pflanzen, der Berücksichtigung des Wachstumsfortschritts sowie der Plausibilität der erzielten Ergebnisse angepasst wurde (Tab. 3). Die Isolation dient der Entnahme von Pflanzenschichten, was die Klassifikationsergebnisse erhöht (Viljanen et al., 2018).

Tab. 3: Die Vegetation wurde aufgrund pflanzensoziologischer Stratifikation und ihrer durchschnittlichen Höhe zur gegebenen Wachstumsphase in verschiedene Schichten isoliert. Die Resultate wurden mit dem RGB Orthomosaik verglichen und auf Richtigkeit überprüft.

Vegetationsschicht	Feinteilung	Wertebereich
Krautschicht	Gräser	0 – 0.25 m
	Zwergsträucher	0.25 – 0.8 m
	Hochstauden, Jungsträucher	0.8 – 1.5 m
Strauchschicht	Sträucher	1.5 – 3.5 m
Baumschicht	Bäume	3.5 – 15 m

Aus dem roten, grünen und blauen Band des Orthomosaiks wird der RGB basierte Vegetationsindex Excess Greenness (ExG) berechnet (Woebbecke, Meyer, Von Bargen & Mortensen, 1995). Er ist sozusagen das Pendant zum NDVI, verwendet aber nur Bänder des sichtbaren Spektralbereichs.

$$ExG = (2 * g) - r - b \quad W_f = \mathbb{R} \setminus \{-2; 2\}$$

Der ExG liegt in einem Wertebereich zwischen -2 und 2 (Torres-Sánchez, López-Granados & Peña, 2015). Ähnlich wie beim NDVI werden negative Zahlen als vegetationslose und positive Werte als vegetationsbedeckte Bereiche eingeteilt (Abb. 6). Der Schwellenwert für die Reklassifizierung wurde hier auf 0.03 erhöht, da sonst zu viele schwachbedeckte Grasflächen als vegetationslos deklariert würden. Torres-Sánchez et al. (2015) erzielten mit dem ExG die besten Klassifizierungsergebnisse.

Vor der Einspeisung in den Bildklassifizierungsablauf wurden alle Layer auf dieselbe Grösse von ca. 46.6 ha zugeschnitten, damit die verzerrten und unscharfen Ränder die Resultate nicht negativ beeinflussen.





Abbildung 6: Vegetationsindex ExG mit Schwellenwert bei 0.03.

Abbildung 7: Vegetationsindex NDVI mit Schwellenwert bei 0.2.



2.3 Datenverarbeitung

Damit aus dem RGB Orthomosaik und der multispektralen Reflektionskarte thematische Karten entstehen, werden die generierten Multiband-Raster-Bilder einer überwachten, objektbasierten Bildklassifizierung unterzogen. Überwacht heisst, dass die Trainingsgebiete vom Anwender selbst erfasst werden. Die RGB und multispektralen Daten durchliefen zwar denselben Ablauf, mussten aber wegen unterschiedlicher Auflösungen getrennt verarbeitet werden.

Mit der Mean-Shift Segmentierung werden nahe gelegene Pixel zu Segmenten, sogenannten Superpixeln, gruppiert. Dabei definieren die Einstellungen der drei Parameter: Spektraldetail (RGB & multispektral = 20), räumliches Detail (RGB & multispektral = 20) und die minimale Segmentgrösse (RGB = 90, multispektral = 20), wie der Detailumfang von Bildelementen aussehen soll. Die aus der Segmentierung entstandenen ähnlichen Bereiche wurden dann als Objekte gruppiert (Abb.8).



Abb. 8: Beispiel einer Segmentierung (rechts) von Zwergsträuchern des RGB-Orthomosaiks (links).

Im Trainingsgebiet-Manager wurden pro Klasse ca. 30 Testgebiete ausgewählt, welche einerseits auf den Informationen der terrestrischen Begehung (Referenzpunkt aus Abbildung 3) und andererseits auf der visuellen Interpretation des Orthomosaik basierten. Es wurde auf eine gesamtflächige Verteilung geachtet, um eine bessere Abdeckung der verschiedenen Reflexionsgrade der Klassen.

Als Klassifizierungswerkzeug wurde der Support Vector Machine (SVM) Klassifikator eingesetzt. Dieser wird in der Forschung häufig verwendet und benötigt beispielsweise gegenüber der Maximum Likelihood-Klassifizierung eine weniger ausgewogene Anzahl Trainingsgebiete pro Klasse sowie keine normale Verteilung der Daten (Durfée et al., 2019; Esri Inc., 2019b). Burai, Deák, Valkó & Tomor (2015) haben mit SVM bei ihren Untersuchungen ebenfalls gute Erfahrungen gemacht. Es folgte ein Vergleich zwischen dem klassifizierten Raster-Bild, dem Orthomosaik und dem zugehörigen segmentierten Layer. Die Trainingsgebiete wurden auf Genauigkeit überprüft und angepasst, bis ein zufriedenstellendes Resultat vorlag. Für die Genauigkeitsanalyse wurde eine Konfusionsmatrix erstellt, welche den Kappa-Übereinstimmungsindex zwischen der klassifizierten Karte und den Referenzdaten angibt.

(i) Einteilung in Lebensräume

Um herauszufinden, wie weit das Orthomosaik und die Reflektionskarte in Lebensräume eingeteilt werden können, durchliefen beide Datensätze die ersten drei Schritte des Klassifikationsprozesses (Abb. 1). Die Ergebnisse wurden mit dem Orthomosaik verglichen. Da die beiden Kameratypen S.O.D.A. und Parrot Sequoia+ nicht die gleiche Auflösung haben, waren die Layer der beiden Datensätze nicht deckungsgleich. Das heisst die Trainingsgebiete aus dem RGB-Datensatz sind in den multispektralen Daten verschoben und vertreten ihre Klassen nicht mehr adäquat. Aus diesem Grund wurde versucht, die Layer mittels Georeferenzierung genau übereinander zu legen. Ein ganzheitliches Resultat war nicht möglich, weshalb die Trainingsgebiete einzeln überprüft und angepasst wurden.

Zudem wurden die Trainingsgebiete auf Repräsentationsgenauigkeit ihrer Klasse inspiziert und wiederum angepasst. Dabei war wichtig, darauf zu achten, dass informationslose Löcher (No-Data-Values Bereiche) nicht in Trainingsgebieten vorkamen, um spätere Fehler auszuschliessen. Bei diesen Löchern handelte es sich um Rekonstruktionsfehler, die während der Vorverarbeitung in Pix4D entstanden. Nach der Klassifikation wurde der Vorgang wiederholt, bis sich für beide Datensätze ein zufriedenstellendes Resultat ergab. Mit Hilfe der Anleitung von Dietl et al. (1981) konnten Polygone um die klassifizierten Lebensräume des RGB Bildes gezogen werden. Zur Überprüfung der Grenzziehung, wurde der Polygon-Layer auf das Orthomosaik gelegt und mit den Referenzpunkten verglichen. Der gleiche Polygon-Layer wurde danach auf die multispektralen Daten gelegt. Die neuen Grenzen wurden zudem mit den Ergebnissen von K. Edelkraut 2017 verglichen.

(ii) Ermittlung der produktiven Weidefläche

Aus dem RGB Orthomosaik wurde mit Hilfe des CHM-Layer die Strauch- und Baumschicht herausgeschnitten. Dem Gesamtbild werden dadurch Grünanteile entzogen, was die Möglichkeit der Falschklassifikation von Weideland minimierte. In einem nächsten Schritt wurden die vom ExG Layer ausgewiesenen vegetationslosen Flächen, wie Steine und offener Boden, vom Orthomosaik entfernt. Je weniger irrelevante Informationen bzw. Farbwerte vorhanden sind, desto besser konnte klassifiziert werden. Der Rest der unproduktiven Weidefläche kann aufgrund mangelnder Genauigkeit des CHM Layer nicht herausgeschnitten werden. Da sie keinen Futterwert haben, sind sie zur Klasse 'unproduktiv' zusammengefasst worden. Die Bergfettweiden mit höherem Futterwert, die Alpinen Magerrasen und die Lägerstellen mit geringerem Futterwert ergaben die Klasse 'produktiv'. Im Anschluss wurden die angepassten BFF-Teilflächen über das 'Produktiv / Unproduktiv' Bild gelegt. Wald und Krummholzgebüsch dominierte Randbereiche, welche nicht als BFF ausgewiesen sind, wurden abgeschnitten. Zur Flächenberechnung wird das Rasterbild in ein Vektorbild umgewandelt.

(iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

Die Fragestellung (iii) versucht herauszufinden, ob jeder Lebensraum ein individuelles Farbspektrum hat, welches beispielsweise in einer Datenbank gespeichert werden könnte und künftigen Luftbilduntersuchungen als Vergleich vorliegen würde. Untersuchungen könnten so um ein Vielfaches vereinfacht werden. Hierzu wurde aus den Trainingsgebieten ein Spektralprofil pro Klasse erstellt. In einer Grafik können die Farbspektren der einzelnen Klassen miteinander verglichen werden. Verlaufen die Linien nahe bei einander, decken die Lebensräume einen ähnlichen Spektralbereich ab. Weisen sie klare Abweichungen auf, ist es möglich sie zu differenzieren.

Tab. 4: Konfusionsmatrix der RGB-Klassifikation ergibt einen Kappa-Übereinstimmungsindex und eine Gesamtgenauigkeit zwischen der klassifizierten Karte und dem Orthomosaik an.

Referenzpunkteschema: Equalized stratified random

Klassen Name	ClassValue	C_1	C_51	C_52	C_54	C_55	C_61	C_62	C_67	Total	U_Acc.	Kappa
extrahiert	C_1	62	0	0	0	0	0	0	0	62	100%	
Zwergsträucher	C_51	0	50	1	0	0	3	2	7	63	79%	
Alpenrosen	C_52	2	5	28	6	0	2	5	0	48	58%	
alpine Windheide	C_54	0	8	5	35	1	0	5	0	54	65%	
Krummholzgebüsch	C_55	1	7	0	0	42	2	0	5	59	71%	
Lägerstellen	C_61	1	12	0	0	19	28	0	1	61	46%	
alpine Magerrasen	C_62	1	6	2	1	1	1	43	2	57	75%	
Bergfettweide	C_67	0	18	0	0	4	3	1	34	61	56%	
Total		67	106	36	42	67	39	56	49	465		
P_Accuracy		93%	47%	78%	83%	63%	72%	77%	69%		69%	
Kappa												65%

3 Resultate

3.1 (i) Einteilung in Lebensräume

RGB Datensatz

Die Abbildung 10 zeigt die durch die RGB Bildklassifizierung ausgewiesenen Lebensräume. Die dunkelblauen Linien stellen die Polygone bzw. Lebensräume dar. Die grauen Bereiche sind die vegetationslosen Flächen: Steine und offener Boden sowie die Baum- und Strauchschichten, welche vorgängig ausgeschnitten wurden. Jedes Polygon stellt aufgrund des Klassifikationsergebnisses einen Lebensraum dar, der sich von den Nachbarsflächen durch eine optische, mengenmäßige Zu- oder Abnahme anderer Klassen unterscheiden lässt.

Die nährstoffreicheren Bergfettweiden nehmen mit zunehmender Höhe ab und die mageren Alpenen Rasen nehmen zu. Die alpinen Windheiden sind wie erwartet auf ausgesetzten Kuppen in höher gelegenen Bereichen zu finden. Auch Zwergsträucher siedeln sich lieber auf Kuppen an, so kann anhand ihrer Verteilung auf der südwestlichen Hälfte des Bildes gut erkannt werden, wie sich das Terrain faltet (Abb. 10).

Demgegenüber ist die Verteilung der Klassen am nordöstlichen Bildrand (Abb. 10) eher heterogen, was zu der Übergangsregion zwischen Weide, Zwergsträuchern, Krummholzgebüsch und Wald passt. Am gleichen Rand sind die grauen Flächen sichtlich grösser.

Das zeigt, dass die Baumgrenze und der Krummholzgürtel durch die Karte verlaufen. In der viereckigen Einbuchtung der Karte ist weiter ersichtlich, dass Krummholzgebüsch fälschlicherweise als Lägerstellen klassifiziert werden. Die restlichen Flächen der Lägerstellen und die Alpenrosen als einzige rote Bildobjekte weisen ein gutes Resultat auf. Allgemein konnte das Gesamtergebnis durch den Abzug der grauen Flächen, sprich das Entfernen von ähnlich grüner Vegetation, wesentlich verbessert werden.

Genauigkeitsanalyse

In den Spalten stehen die wirklichen Klassen der Trainingsgebiete und in den Zeilen die Vorhersage des Klassifikators. Der Kappa-Übereinstimmungsindex gibt an, wie präzise das Klassifikationsergebnis ist. 65% ist ein tiefer Wert. Da nicht alle Steine und offenen Bodenstellen entfernt werden konnten, wurden Punkte aus der Genauigkeitsbewertung, die als Vegetationsklasse klassifiziert wurden, gelöscht. Von ursprünglich 500 Punkten konnten 465 für die Analyse verwendet werden.

Die Alpenrosen wurden mit ihrem Rotton oft als alpine Windheiden oder offenen Boden falsch klassifiziert. Krummholzgebüsch mit satten Grüntönen ist meist fälschlicherweise als Lägerstellen ausgewiesen worden. Oft verwechselt wurden auch die helleren Zwergsträucher mit der grünen Bergfettweide. Im Allgemeinen konnten die extrahierte Klasse, die Krummholzgebüsche und die alpinen Magerrasen am besten klassifiziert werden.




Abb. 9: Lebensraumkarte generiert aus der überwachten Objekt-basierten Bildklassifizierung (OBIA).

Überlagerung Lebensraumgrenzen aus RGB-Datensatz




Abbildung 10: Der Polygon-Layer wurde über das Orthomosaik gelegt, um zu überprüfen, wie gut die Lebensraumeinteilung der Klassifikation erfolgte.

Vergleich Lebensraumgrenzen

Beim Übereinanderlegen des Lebensraumpolygon-Layers auf das Orthomosaik, war eine farbliche Veränderung zu den Nachbarspolygonen in den meisten Fällen ersichtlich, was auf ein erfolgreiches Ergebnis hindeutet (Abb. 11). Wird dieses Ergebnis mit den 2017 kartierten Lebensraumgrenzen (dunkelrot) überlagert (Abb. 12), fällt auf, dass die neuen Lebensräume (dunkelblau) oft kleiner erfasst wurden. Liegen die beiden Grenzfürhungen nahe beieinander, sind die Unterschiede der Lebensräume wahrscheinlich schwer zu definieren.

Abbildung 11: Zum Vergleich der gezogenen Grenzen wurde über die Abbildung 11, die Lebensraumgrenzen von 2017 darübergelegt. Auffällig ist, dass die neuen teilweise kleiner sind.

Vergleich Lebensraumgrenzen





Abb. 12: Als Vergleich wurde der Polygon-Layer des RGB Datensatzes über die Bildklassifizierung des multispektralen Datensatz gelegt. Die Grenzen stimmen teilweise nicht überein. Krummholzgebüsch und andere Klassen wurden deutlich überklassifiziert.



Multispektraler Datensatz

Für den multispektralen Datensatz erstellte Pix4D kein eigenes Höhenmodell. Das Höhenmodell aus dem RGB Datensatz war einerseits wegen unterschiedlicher Auflösung nicht deckungsgleich und konnte andererseits mittels georeferenzieren nicht genau übereinandergelegt werden (Kap. 2 (i) Einteilung in Lebensräume). Um keine falschen Bereiche zu extrahieren, wurden beim multispektralen Datensatz nur die vegetationslosen Flächen, berechnet aus dem NDVI, entfernt (Abb. 13). Die Klasse der Krummholzgebüsch und die Zwergsträucher wurden deutlich überklassifiziert. Die Alpenrosen werden hier stellenweise dichter ausgewiesen und ebenfalls überklassifiziert. Demgegenüber wurden die Bergfettweideflächen und die alpinen Windheiden unterklassifiziert. Die Ausdehnung der Lägerstellen scheint geringer ausgefallen zu sein als in der RGG-Klassifikation und dem Orthomosaik. Sehr gute Ergebnisse lieferte die Klassifizierung der Bäume bzw. des Waldes.

3.2 (ii) Ermittlung der produktiven Weidefläche

Die generierten Lebensraumkarten bildeten die Basis für die Berechnung der produktiven und unproduktiven Flächenanteile.

RGB Datensatz

Die Gesamtgröße des Untersuchungsgebiet beträgt ca. 40.8 ha. In blau sind die unproduktiven Flächen dargestellt, welche sich aus den Klassen Zwergsträucher, Alpenrosen und alpinen Windheiden zusammensetzen. Grün zeigt die produktiven Weideflächen mit Futterwert, die aus den Alpinen Magerrasen, den Bergfettweiden und den Lägerstellen bestehen. Von der Gesamtgröße sind 30% (12.2 ha) unproduktiv und 63% (25.7 ha) produktives Weideland. Die extrahierte Baum- und Strauchschicht machten zusammen mit den vegetationslosen Flächen aus dem ExG 7% (2.9 ha) aus. Sie sind in grau dargestellt.





Abb. 13: Darstellung der prozentualen Verteilung der produktiven, unproduktiven und extrahierten Flächen aus dem RGB Datensatz. In den Balken ist zudem die Fläche in ha angegeben.

Abb. 14: Darstellung der prozentualen Verteilung der 'produktiven', 'unproduktiven' und 'extrahierten Flächen' aus dem MS Datensatz. In den Balken ist zudem die Fläche in ha angegeben.



Die Teilflächen drei und vier enthielten mit 73% und 77% am meisten produktives Weideland (Abb. 14). Die Teilfläche sechs hatte mit 26% auch den höchsten Anteil extrahierter Fläche. Die restlichen fünf Flächen haben nicht mehr ihre ursprüngliche BFF-Grösse, weil sie auf das Untersuchungsgebiet angepasst wurden. In der Fläche eins, welche gemäss Erhebungsdaten keine BFF-Qualität hat, und zwei ist gut die Hälfte (beide 52%) produktives Weideland. Die Flächen fünf, sieben und acht erreichen beinahe 60%. In den tiefer gelegenen Flächen sind die extrahierte Flächen grösser.

Multispektraler Datensatz

Die Grösse aller BFF-Teilflächen zusammen beträgt ebenfalls 40.8 ha. Die unproduktiven, blauen Flächen setzen sich aus den Klassen Wald, Krummholzgebüsch, Zwergsträucher, Alpenrosen und den alpinen Windheiden zusammen (Abb. 15). Gemeinsam bilden sie eine Fläche von 22.6 ha (55%). Die grünen, produktiven Flächen bestehen wie bei den RGB-Daten aus alpinem Magerrasen, Bergfettweiden und Lägerstellen und beliefen sich auf 17.1 ha. Das sind 42% des Untersuchungsgebiets. Die grauen, extrahierten Flächen stellen hier nur die vegetationslosen Bereiche aus Stein oder offenem Boden dar und betrugen 1.1 ha.

Im Vergleich zu den Ergebnissen aus den RGB-Daten ist hier der Anteil produktives Weideland wesentlich kleiner. Nur die Flächen drei (55%), vier (51%) und sieben (50%) wiesen etwa die Hälfte als produktives Weideland aus, alle anderen lagen weit darunter.

3.3 (iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

In ArcGIS kann für jede Klasse ein Spektrales Profil erstellt werden, welches einen Durchschnitt der spezifischen Farbwerte abbildet. In den ersten Bildklassifizierungsdurchläufen wurden pro Klasse knapp 60 Proben ausgewählt. Aufgrund der hohen Datenmengen konnte der Rechner in absehbarer Zeit kein Profil für auch nur eine Klasse erstellen. In einem zweiten Schritt wurden die Trainingsgebiete auf gut die Hälfte reduziert und in einem dritten auf knapp zehn runtergesetzt. Trotz dieser Massnahme konnte kein Ergebnis erzielt werden. Ein Spektralprofil einzelner Trainingsgebiete ist aufgrund verändernder Farbtöne nicht repräsentativ.

4 Diskussion

Diese Arbeit prüft, ob der Einsatz von Drohnen zur Abgrenzung von Lebensräumen im Sömmerungsgebiet hilfreich ist. Dafür wurden Luftbildaufnahmen der Alp Muotsevas einer überwachten Objekt-basierten Bildklassifizierung unterzogen, um eine qualitative Lebensraumkarte zu erhalten, anhand jener die produktive Weidefläche berechnet werden kann.

Oft kann sich im Wind bewegende Vegetation während des Flugs nicht identifiziert werden (Carrivick et al., 2016). Der leichte Wind während der Befliegung hatte indes keinen negativen Einfluss auf die Pix4D Ausgabeprodukte. Allerdings konnten nicht alle weissen Steinoberflächen vollständig rekonstruiert werden, weshalb es zu informationslosen Löchern im Orthomosaik gekommen ist. Gemäss Carrivick et al. (2016) ist das vor allem bei stark reflektierenden Landformen wie Stein, Glas oder Schnee eine bekannte Schwierigkeit, die erst bei der Datenverarbeitung im Büro bekannt wird. Methoden der Georeferenzierung, wie die PPK-Methode, sind für solche Fälle unerlässlich. Hier handelt es sich bei den informationslosen Bereichen lediglich um kleine Pixelgruppen innerhalb der Klasse Stein, welche schliesslich extrahiert wurden. Bei einer Weiterverarbeitung der Daten ist darauf zu achten, dass solche Löcher nicht innerhalb von Trainingsgebieten liegen, um spätere Klassifikationsfehler zu vermeiden.

Die Erfassung von Referenzpunkten bei der terrestrischen Begehung ist sehr hilfreich, da nicht alle evidenten Veränderungen im Gelände auch auf dem Orthomosaik ersichtlich waren (z.B. Anhäufung von weissen Flechten). Ihre ausführliche Dokumentation ist deshalb wichtig, damit die Trainingsgebiete später am richtigen Ort gesetzt werden können. Die Map Marker-App ist privat entwickelt worden und in gewissen Bereichen (Fotodokumentation, Daten-Synchronisation usw.) noch nicht ausgereift. In künftige Arbeiten wäre zu prüfen, ob die Verwendung der kostenlosen ArcGIS Collector App für eine botanische Erfassung geeigneter wäre. Allenfalls könnten Referenzpunkte direkt einem vordefinierten Klassifikationsschema zugeordnet werden. Eine Erfassung der Indikatorpflanzen wäre ebenfalls denkbar. Da die Collector App von derselben Herstellergruppe ist, ist anzunehmen, dass die Datensynchronisation kompatibler wäre. Eine elektronische Datenerfassung während der terrestrischen Begehung wird bisher kaum angewendet.



Abb. 15: Unterschied der Klassifikationsergebnisse des multispektralen Datensatzes bei Erhöhung der minimalen Segmentgrösse 10 (links) auf 20 (rechts). Alpenrosen und andere Zwergsträucher werden deutlich weniger überklassifiziert.

Einen bedeutenden Einfluss auf die Ergebnisse haben die Einstellungen der Segmentierungsparameter. Sie bestimmen die Grösse, Form und räumliche Verteilung der Bildobjekte und nur ihre richtige Kombination ergibt eine gute Basis für die Bildklassifikation (Hay, Castilla, Wulder & Ruiz-Gallardo, 2005; Laliberte et al., 2011). Im multispektralen Datensatz führte eine Erhöhung der minimalen Segmentgrösse von 10 auf 20 zu bedeutend besseren Klassifikationsergebnissen. Die Überklassifikation von Alpenrosen und anderen Zwergsträuchern konnte deutlich reduziert werden (Abb. 16).

Die Aufbereitung der Luftbilddaten in Pix4D mit der Structure-from-Motion-Methode lieferte qualitativ gute Ergebnisse. Carrivick et al. (2016) meinen, dass SfM in der Anschaffung der Hard- und Software billiger ist. Zurzeit ist die effiziente Visualisierung der SfM-Daten in einem Standard-Industrie-GIS aufgrund der teils grossen Datenmengen noch problematisch. Dennoch ist die Anwendung von SfM, aufgrund der einfachen Bedienung und der qualitativen Ergebnisse in künftigen Untersuchungen sehr zu empfehlen.

4.1 (i) Einteilung in Lebensräume

Aus der terrestrischen Begehung konnten Referenzpunkte gesammelt werden, welche in der Bildklassifizierung aufgrund von Farbwerten für die Zuweisen der Klassen geholfen haben. Daraus ist eine thematische Karte entstanden, welche die Verteilung von Lebensräumen zeigt.

Werden die Klassifizierungsergebnisse des RGB- und des multispektralen Datensatzes mit dem Orthomosaik verglichen, zeigen die RGB-Ergebnisse ein genaueres Abbild (Abb. 17). Krummholzgebüsch, Alpenrosen, Zwergsträucher wurden in den multispektralen Daten überklassifiziert. Bergfettweiden, alpine Windheiden und Lägerstellen wurden unterklassifiziert. Einzig der Wald lieferte wesentlich bessere Klassifizierungsergebnisse in den multispektralen Resultaten. Ein Grund dafür sind die in der Methodik erwähnten unterschiedlichen Auflösungen der beiden Kamertypen (Torres-Sánchez et al., 2015). Die tiefere Auflösung führte zur Verschiebung der Trainingsgebiete und zu weniger deutlichen Bildobjekten. An ihren Rändern entstehen sogenannte Mischpixel, welche keiner eindeutigen Klasse zugeordnet werden können. Je kleiner die Bildobjekte sind, desto mehr Mischpixel gibt es. Zur Berichtigung könnten die multispektralen Daten nochmals neu in Pix4D eingelesen werden, mit Passpunkten aus dem RGB-Daten versehen und neu verarbeitet. Da Komárek et al. (2018) in ihren Bildklassifizierungen eines Arboretums mit multispektralen Daten Pflanzen teils bis auf Spezies-Level besser klassifizieren

konnten als mit den RGB-Daten, wäre es interessant, den gleichen Flug entweder mit geringerer Flughöhe (Torres-Sánchez et al., 2014) oder mit einem bessern multispektralen Sensor zu wiederholen. Auch Ahmed et al. (2017) erzielten mit den RGB-Daten tiefere Klassifikationsgenauigkeit als mit multispektralen. Die Auflösung ihres RGB-Sensors war um 2 MB kleiner (Sony DSC-WX220, 18MB), für die multispektralen Bilder wurde ebenfalls die Parrot Sequoia verwendet. Eine andere Möglichkeit zur Reduktion der Mischpixel wäre, bei der Segmentierung die minimale Grösse herabzusetzen (Torres-Sánchez et al., 2015). Auf diese Weise setzten sich die kleineren Objekte aus einem repräsentativeren Farbspektrum zusammen. Allerdings kann sich das wie erfahren negativ auf grössere Objekte auswirken.

Die Vegetationsindizes ExG und NDVI liefern wie bei Viljanen et al. (2018) auch hier gute Resultate zur Unterscheidung von bedeckten und vegetationslosen Bereichen. Die anschließende Entnahme dieser vegetationslosen Bereiche basiert auf dem gleichen Prinzip der Minderung von Mischpixeln, was primär die Klassifizierung von hellen Lebensräumen wie beispielsweise den alpinen Magerrasen verbessert. Viljanen et al. (2018) verwenden in ihrer Untersuchung mehrere Indizes gleichzeitig und erhalten so die besten Resultate. Aus welchen die beste Kombination für die Bildklassifizierung entsteht, ist meist für jedes Projekt unterschiedlich und muss durch Anwendung eruiert werden.

Bei beiden Datensätzen wurde anfangs vor allem die Strauchschicht überklassifiziert. Bei den RGB Daten gab es zudem Schwierigkeiten mit der Klassifikation von Wald, welcher im Ergebnis vor der Reklassifikation fälschlicherweise über die gesamte Untersuchungsfläche verteilt war. Gemäss Ahmed et al. (2017) ist dies ein bekanntes Problem und beruht auf der ähnlichen spektralen Farbzusammensetzung der Vegetationsgesellschaften. Der Abzug des Höhenmodells hat hier zu sehr positiven Ergebnissen geführt.

Aus diesen Ergebnissen lässt sich schliessen, dass der Einbezug von zusätzlichen Daten (Vegetationsindizes, Höhenmodell) die Bildklassifikation wesentlich verbessert. Komárek et al. (2018) haben zudem bessere Resultate mit Wärmebildkameras erreicht, Viljanen et al. (2018) mit der Kombination verschiedener Vegetationsindizes, Höhenmodellen und Wärmebildkameras. Mit einem guten Höhenmodell sollte es möglich sein, die groben Vegetationsschichten so voneinander zu trennen, dass jede Schicht separat klassifiziert werden kann. Ob dies zu verbesserten Resultaten führt, sollte Gegenstand künftiger Untersuchungen sein.




Abb. 16: Die Klassifikationsergebnisse der RGB- und multispektralen Daten werden hier anhand von vier Beispielen verglichen. (e) stellt ein unglaublich gutes Abbild von (a) dar. In (f) ist die Falschklassifikation von Alpenrosen und die Minderklassifikation von Lägerstellen ersichtlich. (g) zeigt die Entnahme von Vegetationsschichten und in (h) ist die heterogene Verteilung in strukturreichem Gelände ersichtlich. Die multispektralen Daten zeigen ein weniger genaues Abbild des Orthomosaiks.

Es wäre zu prüfen, ob eine zusätzliche Befliegung gegen Ende des Sommers einen positiven Effekt auf die Unterscheidung der Lebensräume hat. Zu diesem Zeitpunkt verändern die Vegetationsgesellschaften die Farbe und reduzieren die Produktion des Chlorophylls. Wie Torres-Sánchez et al. (2014) schreiben, verändert das die Reflexionsgrade in den Blattstrukturen. Eine Differenzierung der Pflanzen bzw. der Lebensräume zu dieser Jahreszeit könnte deshalb speziell bei den multispektralen Daten zu besseren Resultaten führen (Durfée et al., 2019; Torres-Sánchez et al., 2014).

Der Kappa-Übereinstimmungsindex (65%) und die Gesamtgenauigkeit (69%) sind eher tief ausgefallen. Da die zufällig generierten Punkte aus der Genauigkeitsbewertung manuell den tatsächlichen Klassen zugeordnet werden, können Fehler in der Bearbeitung der Daten entstehen. Alpenrosen konnten gegenüber alpinen Windheiden, den restlichen Zwergsträuchern sowie offenen Bodenstellen, welche durch den ExG nicht entfernt wurden, am schlechtesten abgegrenzt werden. Die bläulichen, silbernen Weiden der Klasse Krummholzgebüsch werden gut klassifiziert, hingegen werden die Grünerlen oft fälschlicherweise den Zwergsträuchern zugeordnet. Bergfettweiden sind nährstoffreicher und grüner als alpine Magerrasen, weshalb die Klassifizierung in ihren Übergangsbereichen schwierig ist. Die Konfusionsmatrix zeigt auf, welche Klassen schwerer und besser abgrenzbar sind. Diese Ergebnisse sollten in künftigen Untersuchungen in Sömmerungsgebieten berücksichtigt werden. Die Auflösung des Orthomosaiks schränkt teilweise die sichere Zuweisung einer Klasse ein, weshalb unter Verwendung von hyperspektralen Sensoren die Gesamtgenauigkeit steigen sollte (Govender, Chetty, Naiken & Bulcock, 2008; Komárek et al., 2018).

4.2 (ii) Ermittlung der produktiven Weidefläche

Terrestrische Begehungen zur Kartierung der BFF in Sömmerungsgebieten sind zeitaufwändig und nicht immer einfach möglich. Es wurde vermutet, dass der Einsatz von Drohnen ein vielversprechendes Hilfsmittel bei der Ersterfassung oder für die Überwachung von Veränderungen sein könnte.

Die aus der Lebensraumeinteilung entstandene thematische Karte dient als Ausgangslage für die Berechnung der produktiven und unproduktiven Flächen. Alle ausgewiesenen BFF-Teilflächen der RGB Daten erreichten einen produktiven Anteil zwischen 50% bis 80%. Es ist deutlich zu erkennen, dass in heterogenen Flächen der Anteil an unproduktivem Weideland grösser ist. Das schrittweise Entfernen von Daten hat sich auch für die Beantworten dieser Fragestellung (ii) als Methode bewährt.

Die BFF-Teilflächen drei und vier entsprechen derselben Grösse wie in den Erhebungsdaten von 2017, die anderen wurden auf das Untersuchungsgebiet verkleinert. Die Qualitätsanteile von 2017 wurden nach der von AGRIDEA beschriebenen Methode erfasst (Hedinger, 2014). Der Qualitätsanteil beinhaltet Weidefläche mit BFF-Qualität (6 Indikatorpflanzen). Die unproduktiven Elemente (Steine, Weg, Zwergsträucher, Disteln usw.) werden nur in Bezug auf den Qualitätsanteil geschätzt, nicht auf die ganze Teilfläche. In den Ergebnissen von 2019 sind die un- / produktiven und extrahierten Anteile in Bezug auf die gesamte BFF-Teilfläche gerechnet. Die Indikatorpflanzen wurden nicht berücksichtigt. Ein direkter Vergleich ist aufgrund der unterschiedlichen Methoden nicht möglich, weshalb keine abschliessende Genauigkeit dieser Resultate angegeben werden kann. Es wird aber vermutet, dass der um 7% höhere Anteil produktiver Fläche in der Teilfläche vier deshalb zustande kommt, weil feuchte, nährstoffreiche Mulden und Lägerstellen zu den produktiven Flächen zählen (Tab. 5). Dies erklärt aber nicht, den um 17% tieferen in der Fläche drei.

Erhebungsdaten 2017

Teilflächennummer	1	2	3	4	5	6	7	8
Qualitätsanteil	0%	80%	90%	70%	80%	0%	80%	100%
unproduktiv Anteil der Testfläche	0%	20%	10%	20%	30%	0%	15%	50%
effektiver Abzug der Testfläche	0%	10%	0%	10%	20%	0%	5%	40%

RGB-Ergebnisse 2019

Teilflächennummer	1	2	3	4	5	6	7	8
produktiv	52%	52%	73%	77%	58%	41%	59%	58%
unproduktiv	35%	43%	23%	20%	34%	34%	31%	32%
extrahiert	13%	5%	4%	3%	8%	26%	10%	10%

Tab. 5 und 6: Gegenüberstellung der 2017 erfassten Qualitätsanteile und den RGB-Ergebnissen aus 2019. Fläche eins und sechs haben keine BFF-Qualität und zeigen deshalb oben 0%. Ein direkter Vergleich ist aufgrund verschiedener Methoden nicht möglich.

Generell sind die produktiven Flächen in den vorliegenden Ergebnissen tiefer. Eine Erklärung dafür könnte sein, dass mit den Vegetationsindizes viele kleine Steine entfernt werden, welche bei der Schätzung wahrscheinlich kaum berücksichtigt werden können. Die Fläche eins wäre eigentlich keine BFF-Fläche, zeigt allerdings in der auf das Untersuchungsgebiet angepassten Form einen produktiven Anteil von 52%. Wäre diese BFF-Teilfläche in Realität kleiner, könnte sie mit dem Vorkommen der Indikatorpflanzen beitragsberechtigt sein. Mit der angewandten Methode würden dementsprechend die Abzüge für unproduktive Flächen höher, dafür könnte aufgrund der Resultate die BFF-Grenzziehung angepasst werden und mehr Qualitätsflächen ausgewiesen. Ein Gewinn für beide Parteien: Landwirt und Kanton.

In Bezug auf die Qualität der Untersuchungsflächen könnte die Erfassung einzelner Pflanzenarten helfen. Komárek et al. (2018) haben mit multispektralen Sensoren Arten in einem Arboretum bestimmt, Durfee et al. (2019) haben vegetative Veränderungen in der Landschaft aufgezeigt und Babbì et al. (2017) konnten in einem Gebiet die Verbreitung des invasiven Adlerfarns analysieren. Dabei handelt es sich hingegen um grössere, markantere Pflanzenobjekte. Ein Untersuchungsgebiet wie das vorliegende, ist durch die Verzahnung der Lebensräume viel komplexer. Die Erfassung einzelner Graslandarten ist mit der verwendeten Technologie nicht möglich.

Auch wenn mit der angewandten Methode die Qualitätsanteile nicht ermittelt werden konnten, können dennoch die unproduktiven Elemente berechnet anstatt geschätzt werden. Dies bedeutet eine Entlastung für Fachpersonen, welche nun ihre Resultate vor dem Landwirt und dem Kanton rechnerisch darlegen können.

4.3 (iii) Identifikation des spezifischen Farbspektrums eines Lebensraumes

Es wurde versucht aus den Trainingsgebieten pro Klasse ein Spektrales Profil zu erstellen, um den Lebensräumen ein spezifisches Farbspektrum zuzuweisen. Unglücklicherweise konnte der Rechner die grossen Datenmengen nicht verarbeiten.

Die dichten grünen Flecken in den Alpenin Magerrasen bestehen im Untersuchungsgebiet mehrheitlich aus Rasenschmielen und Alpen-Lieschgras, typische Feuchtwiesenvertreter (Abb. 18). Die Bilder (e) und (f) in Abbildung 17 zeigen, dass sie im Übergang zu den alpinen Rasen als Bergfettweide klassifiziert werden. An diesem Beispiel ist gut zu erkennen,



Abb. 17: Ein Beispielbild aus dem Untersuchungsgebiet mit einem monotonen Rasenschmielen Bestand.

dass die Dichte und die Zusammensetzung einen Einfluss auf die spektrale Farbzusammensetzung haben. In Lebensraumübergängen wird es demnach nicht möglich sein ein eindeutiges Spektralprofil zu erfassen. Die Alpenrosen können hier durch die roten Blüten sehr gut isoliert werden. Allerdings sieht das ausserhalb ihrer Blühphase anders aus. Da das Farbspektrum einer Pflanze, folglich auch eines Lebensraumes über die Jahreszeiten hinweg ändert, wird es schwierig, ein eindeutiges Farbspektrum überhaupt zu definieren (Govender et al., 2008).

Lopatin, Fassnacht, Kattenborn & Schmidlein (2017) haben herausgefunden, dass die Klassifikation von Grasslandarten auf Artniveau bei wenig komplexen Vegetationsstrukturen und hoher Auflösung möglich ist. Schon Jacobsen, Broge & Hansen nahmen 1995 einzelne Spektralprofile von Weizentypen auf. Beide verwenden dafür hochaufgelöste hyperspektrale Daten.

Hyperspektrale und multispektrale Daten nehmen Wellenlängen aus demselben elektromagnetischen Spektrum auf. Der Unterschied liegt in der Anzahl Spektralkanäle und ihren Abständen. Während multispektrale Bilder drei bis zehn Spektralkanäle haben, sind es bei hyperspektralen hunderte bis tausende, in einem engeren Abstand zwischen 10-20 nm (Burai et al., 2015; Govender et al., 2008). Dadurch dass die Wellenlängen der hyperspektralen Daten viel enger beieinanderliegen, kann ein viel kontinuierlicheres Spektralprofil von Pflanzen erfasst werden. In der Schweiz haben Psomas, Zimmermann, Kneubühler, Kellenberger & Itten (2005) versucht, mit hyperspektralen Sensoren und verschiedener jahreszeitlichen Wachstumsphasen diverse Graslandtypen zu differenzieren. Die besten Ergebnisse resultierten durch das schrittweise Entfernen von Vegetationsschichten.

Die Identifikation spezifischer Farbspektren ist demnach ein aktuelles Thema an der Forschungsfront. Adão et al. (2017) haben in ihrer Untersuchung eine Liste mit den momentan gebräuchlichen hyperspektralen Sensoren, welche mit Drohnen verwendet werden können, zusammengestellt. Sie geben auch eine Zusammenfassung der Vor- und Nachteile in Zusammenhang mit der Arbeit von hyperspektralen Daten. Momentan sind diese Sensoren für eine breite Masse von Anwendern noch etwas teuer, mit dem technologischen Fortschritt wird sich dies aber bald ändern. Dann braucht es genügend Fachpersonen, die diese Daten einerseits aus Umweltsicht verstehen und andererseits mit technischem Wissen verarbeiten können.

4.4 Kontext zur Nachhaltigkeit

Wie zu Beginn dieser Arbeit bereits erwähnt, sind nach Lauber et al. (2017) Sömmerungsgebiete mitunter die artenreichsten Lebensräume der subalpinen und alpinen Höhenstufen. Sie liefern aber auch Nahrung, sind ein Wahrzeichen für die Schweizer Kulturlandschaft und bieten dem Menschen Raum für Erholung und Inspiration. Eine Verschlechterung der Biodiversität würde automatisch zu einer Abnahme dieser Ökosystemdienstleistungen führen (BAFU, 2017). Deshalb ist die Sicherung dieses Schweizer Naturkapitals sowohl in der Bundesverfassung (Art. 78, „Bundesverfassung der Schweizerischen Eidgenossenschaft (BV)“, 2000), als auch im Natur- und

Heimatschutz Gesetz (Art. 18, „Bundesgesetz über den Natur- und Heimatschutz (NHG)“, 1967) verankert. Zudem haben Bund und Kantone mit der Inventarisierung und Finanzierung von BFF in Sömmerungsgebieten direkte Massnahmen zu deren Erhalt und Förderung ergriffen (BAFU, 2017). Der Einsatz von Drohnen hilft, diese Massnahmen auch über grössere und längere Zeiträume (Durfée et al., 2019), effizient und in guter Qualität durchzuführen. Damit soll im Sinne der Nachhaltigkeit die Vielfalt an Genen, Arten und Lebensräumen als existenzielle Grundlage für den Menschen, sein Leben und Wirtschaften heute und in Zukunft erhalten bleiben (BAFU, 2017).

4.5 Fazit

Die generierte Lebensraumkarte aus dem RGB-Datensatz widerspiegelt die Klassen erstaunlich gut. Basierend auf dem Orthomosaik und der Klassifikationsergebnisse kann vor einer terrestrischen Begehung eine erste Einschätzung über die Verteilung von Lebensräumen gewonnen werden. Eindeutige Flächen müssen, bis auf die Testflächen zur Identifikation der Indikatorpflanzen, nicht mehr genaustens abgelaufen und unproduktive Anteil nicht mehr geschätzt werden. Unklaren Bereichen kann von Anfang an mehr Aufmerksamkeit geschenkt werden. Die Ergebnisse zeigen auf, welche Klassen gut oder schwierig abgrenzbar sind. Vegetationsindizes und Höhenmodelle sowie die Entnahme von Daten steigern die Genauigkeit der Ergebnisse deutlich. Zudem ist davon auszugehen, dass mit hyperspektralen Daten noch bessere Resultate erzielt würden. Demzufolge ist der Einsatz von Drohnen zur Abgrenzung von Lebensräumen ein vielversprechendes Hilfsmittel und sollte weiterhin untersucht werden.

5 Literaturverzeichnis

- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R. et al. (2017). *Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry*. *Remote Sensing*, 9(1110), 30.
- Babbi, M., Widmer, S., Ochsner, P. & Krüsi, B. (2017). *Hilfe von oben: Erfassung von Adlerfarnbeständen mit Drohnen*. *Vierteljahrsschrift der Naturforschenden Gesellschaft in Zürich*, 162(3/4), 10–11.
- BAFU. (2017). *Biodiversität in der Schweiz: Zustand und Entwicklung. Ergebnisse des Überwachungssystems im Bereich Biodiversität, Stand 2016*. Umwelt Zustand No. 1630. (S. 60). Bern: Bundesamt für Umwelt.
- Baltisberger, M., Nyffeler, R. & Widmer, A. (2013). *Systematische Botanik (4. Auflage.)*. Zürich: vdf Hochschulverlag AG.
- Baumgärtel, A. & Landrock, H. (2018). *Die Industriedrohne - der fliegende Roboter. Professionelle Drohnen und ihre Anwendung in der Industrie 4.0*. Springer Vieweg.
- Benz, R. (2014a). *Biodiversitätsförderflächen BFF Zeigerpflanzen im Sömmerungsgebiet*. AGRIDEA.
- Benz, R. (2014b). *Biodiversitätsförderung Qualitätsstufe II: Von artenreichen Grün- und Streuflächen im Sömmerungsgebiet gemäss Direktzahlungsverordnung (DZV)*. Merkblatt No. 2360. (S. 6). Lausanne: AGRIDEA.
- Blaschke, T. (2009). *Object based image analysis for remote sensing*. *ISPRS Journal of Photogrammetry and Remote sensing*, (65), 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Bundesamt für Landwirtschaft (BUWAL). (2018). *Überblick: Direktzahlungen an Sömmerungs- und Gemeinschaftsweidebetriebe*.
- Bundesverfassung der Schweizerischen Eidgenossenschaft (BV). (1. Januar 2000). SR 101. (Stand: 23. September 2013).
- Burai, P., Deák, B., Valkó, O. & Tomor, T. (2015). *Classification of Herbaceous Vegetation Using Airborne Hyperspectral Imagery*. *Remote Sensing*, (7), 2046–2066. <https://doi.org/10.3390/rs70202046>
- Carrivick, J. L., Smith, M. W. & Quincey, D. J. (2016). *Structure from Motion in the Geosciences. New Analytical Methods in Earth and Environmental Science (1. Auflage)*. Chichester, West Sussex, PO19 8SQ, UK: John Wiley & Sons Ltd.
- Christen, M., Guillaume, M., Jablonowski, P., Lenhart, P. & Moll, K. (2018). *Zivile Drohnen - Herausforderungen und Perspektiven*. vdf Hochschulverlag AG.
- Delarze, R., Gonseth, Y., Eggenberg, S. & Vust, M. (2015). *Lebensräume der Schweiz (3. vollständig überarbeitete Auflage.)*. Bern: Ott.
- Dietl, W., Berger, P. & Ofner, M. (1981). *Die Kartierung des Pflanzenstandortes und der futterbaulichen Nutzung von Naturwiesen*. Zürich Reckenholz: Zürich: FAP + AGFF.
- Durfée, N., Ochoa, C. G. & Mata-Gonzalez, R. (2019). *The Use of Low-Altitude UAV Imagery to Assess Western Juniper Density and Canopy Cover in Treated and Untreated Stands*. *Forests*, 10(296). <https://doi.org/10.3390/f10040296>
- eMotion. (2019). Cheseaux-sur-Lausanne: senseFly.
- Esri Inc. (2019). *ArcGIS Pro*. en, de, Redlands, California 92373-8100, USA.
- Govender, M., Chetty, K., Naiken, V. & Bulcock, H. (2008). *A comparison of satellite hyperspectral and multi-spectral remote sensing imagery for improved classification and mapping of vegetation*. *Water SA*, 34(2). <https://doi.org/10.4314/wsa.v34i2.183634>
- Green, K., Congalton, R. G. & Tukman, M. (2017). *Imagery and GIS. Best Practices for Extracting Information from Imagery (1.)*. Redlands, California: Esri Press.
- Hay, G. J., Castilla, G., Wulder, M. & Ruiz-Gallardo, J. R. (2005). *An automated object-based approach to the multiscale image segmentation of forest scenes*. *International Journal of Applied Earth Observation and Geoinformation*, 7(4). <https://doi.org/10.1016/j.jag.2005.06.005>
- Hedinger, C. (2014). *Artenreiche Grün- und Streuflächen im Sömmerungsgebiet. Eine Beurteilungshilfe für Alpbewirtschaftende*. AGRIDEA.
- Hunt Jr., E. R. & Daughtry, C. S. T. (2018). *What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?* *International Journal of Remote Sensing*, (39), 5345–5376. <https://doi.org/10.1080/01431161.2017.1410300>
- Jacobsen, A., Broge, N. H. & Hansen, B. U. (o. J.). *Monitoring wheat fields and grasslands using spectral reflectance data*. *Gehalten auf der International Symposium on Spectral Sensing Research (ISSR)*, Melbourne, Australia.

- Jucker, P. & Werder, C. (2015). *Verbuschung und Problem-pflanzen im Sömmerungsgebiet: Leitfaden für Kontrollierende*. AGRIDEA.
- Komárek, J., Klouček, T. & Prošek, J. (2018). The potential of Unmanned Aerial Systems: A tool towards precision classification of hard-to-distinguish vegetation types? *International Journal of Applied Earth Observation and Geoinformation*, (71), 9–19. <https://doi.org/10.1016/j.jag.2018.05.003>
- Laliberte, A. S., Goforth, M. A., Steele, C. M. & Rango, A. (2011). Multispectral Remote Sensing from Unmanned Aircraft: Image Processing Workflows and Applications for Rangeland Environments. *Remote Sensing*, (3), 2529–2551. <https://doi.org/10.3390/rs3112529>
- Lauber, K., Wagner, G., Gyax, A., Eggenberg, S., Bornand, C., Juillerat, P. et al. (2018). *Flora Helvetica (Sechste, vollständig überarbeitete Auflage.)*. Bern: Haupt Verlag.
- Lauber, S., Herzog, F., Seidl, I., Böni, R., Bürgi, M., Gmür, P. et al. (2013). *Zukunft der Schweizer Alpwirtschaft. Fakten, Analysen und Denkanstöße aus dem Forschungsprogramm AlpFUTUR*. Birmensdorf: Eidg. Forschungsanstalt WSL; Zürich-Reckenholz, Forschungsanstalt Agroscope Reckenholz-Tänikon. Verfügbar unter: <http://www.wsl.ch/ebooks/alpfutur/de>
- Lauber, S., Schüpbach, B. & Koch, B. (2017). Artenvielfalt im Sömmerungsgebiet. *HOTSPOT*, (27), 14–16.
- Li, M., Zang, S., Zhang, B., Li, S. & Wu, C. (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatiocontextual Information. *European Journal of Remote Sensing*, 47(1), 389–411. <https://doi.org/10.5721/EuJRS20144723>
- Lopatin, J., Fassnacht, F. E., Kattenborn, T. & Schmidlein, S. (2017). Mapping plant species in mixed grassland communities using close range imaging spectroscopy. *Remote Sensing of Environment*, 201, 12–23. <https://doi.org/10.1016/j.rse.2017.08.031>
- OECD Umweltprüfbericht Schweiz 2017 (Kurzfassung). (2017). . Bern: Bundesamt für Umwelt.
- Pix4Dmapper. (2019). Prilly:
- Psomas, A., Zimmermann, N. E., Kneubühler, M., Kellenberger, T. & Itten, K. (2005). Seasonal variability in spectral reflectance for discriminating grasslands along a dry-mesic gradient in Switzerland. *Gehalten auf der 4th EARSeL Workshop on Imaging Spectroscopy*. <https://doi.org/10.5167/uzh-97041>
- senseFly eBee plus. Herstellerbroschüre. (2018). . senseFly Parrot Group.
- theandroidseeb. (2019). Map Marker. en, . Verfügbar unter: <https://www.mapmarker.app>
- Tomaščík, J., Mokroš, M., Surový, P., Grznárová, A. & Merganič, J. (2019). UAV RTK/PPK Method—An Optimal Solution for Mapping Inaccessible Forested Areas? *Remote Sensing*, 11(721), 19. <https://doi.org/10.3390/rs11060721>
- Torres-Sánchez, J., López-Granados, F. & Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, (115), 43–52. <https://doi.org/http://dx.doi.org/10.1016/j.compag.2015.03.019>
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I. & López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, (103), 104–113.
- Verordnung über die Direktzahlungen an die Landwirtschaft. (23. Oktober 2013). SR 910.13. (Stand: 1. Januar 2019).
- Viljanen, N., Honkavaara, E., Näsi, R., Hakala, T., Niemeläinen, O. & Kaivosoja, J. (2018). A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* 2018, 8, 28. <https://doi.org/10.3390/agriculture8050070>
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K. & Mortensen, D. A. (1995). Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions. *Transactions of the ASABE*. <https://doi.org/10.13031/2013.27838>
- Zhang, X., Wu, S., Yan, X. & Chen, Z. (2016). A global classification of vegetation based on NDVI, rainfall and temperature. *International Journal of Climatology*. <https://doi.org/10.1002/joc.4847>